

MONITORIZACIÓN NO INTRUSIVA DE CARGA PARA CARACTERIZACIÓN DE CONSUMOS EN REDES ELÉCTRICAS INTELIGENTES

POR
DIANA LUCIA RACINES HIDALGO

TESIS DE MAESTRÍA

DIRECTOR
Dr. JOHN E. CANDELO B.

UNIVERSIDAD DEL NORTE
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

MAESTRÍA EN INGENIERÍA ELÉCTRICA

BARRANQUILLA, COLOMBIA

2014

RESUMEN

Monitorización No Intrusiva De Carga Para Caracterización De Consumos En Redes Eléctricas Inteligentes

La modernización de las redes eléctricas hacia redes eléctricas inteligentes implica la implementación de nuevas herramientas y tecnologías a lo largo de todos los agentes que conforman el sistema, abriendo paso al desarrollo de nuevas funcionalidades.

En el marco de esta tendencia de modernización, la presente tesis documenta la investigación llevada a cabo para el desarrollo de una herramienta útil para el usuario final del servicio de energía eléctrica. En este sentido, el interés es desarrollar un modelo que permita realizar un monitoreo no intrusivo de una instalación eléctrica, de tal forma que en todo momento se pueda conocer la forma como esta consume energía sin necesidad de realizar una medición directa sobre cada carga que la conforma.

El modelo propuesto involucra el uso de dos tipos de redes neuronales artificiales, las cuales son desarrolladas empleando como datos de entrada varias combinaciones de parámetros eléctricos. Los diferentes casos realizados son evaluados con el fin de establecer los parámetros que generan un mejor desempeño del modelo.

Las pruebas realizadas al modelo propuesto mostraron que es posible establecer satisfactoriamente el estado de operación de las cargas que conforman una instalación, de tal forma que su consumo de energía eléctrica pueda ser caracterizado.

TABLA DE CONTENIDO

- CAPÍTULO 1.....12**
 - INTRODUCCIÓN12
 - 1.1. PLANTEAMIENTO DEL PROBLEMA14
 - 1.2. OBJETIVOS16
 - 1.3. ALCANCES16
 - 1.4. LIMITACIONES17
- CAPÍTULO 2.....18**
 - REDES ELÉCTRICAS INTELIGENTES.....18
 - 2.1. DEFINICIONES18
 - 2.1.1. SMART GRID18
 - 2.1.2 INFRAESTRUCTURA AVANZADA DE MEDICIÓN (AMI)20
 - 2.1.3. EFICIENCIA ENERGÉTICA.....21
 - 2.1.4. GESTIÓN DE LA DEMANDA.....22
 - 2.2. ESTADO DEL ARTE EN REDES ELÉCTRICAS INTELIGENTES.....24
 - 2.3. ESTADO DEL ARTE EN INFRAESTRUCTURA AVANZADA DE MEDICIÓN27
- CAPÍTULO 3.....29**
 - SISTEMAS DE MONITOREO DE CARGAS ELÉCTRICAS.....29
 - 3.1. SISTEMA DE MONITOREO INTRUSIVO DE CARGA.....29
 - 3.2. SISTEMA DE MONITOREO NO INTRUSIVO DE CARGA (NILM)30
 - 3.2.1. CLASIFICACIÓN DE SISTEMAS DE MONITOREO NO INTRUSIVO..31
 - 3.2.2. ESTUDIO DE CARGAS.....32

3.3. ESTADO DEL ARTE EN SISTEMAS DE MONITOREO NO INTRUSIVO DE CARGA.....	34
3.3.1. REDES NEURONALES ARTIFICIALES (RNA) Y SU APLICACIÓN EN EL MONITOREO NO INTRUSIVO.....	37
CAPÍTULO 4.....	41
DEFINICIÓN DEL MODELO DE MONITOREO NO INTRUSIVO DE CARGA...	41
4.1. ESTUDIO DE CARGAS ELÉCTRICAS	41
4.1.1. PRIMER GRUPO DE CARGAS.....	42
4.1.2. SEGUNDO GRUPO DE CARGAS.....	43
4.2. ESTRUCTURA DEL MODELO DE MONITOREO NO INTRUSIVO.....	45
4.2.1. ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES.....	48
CAPÍTULO 5.....	52
DESARROLLO DEL MODELO DE MONITOREO NO INTRUSIVO DE CARGA	52
5.1. PRIMER GRUPO DE CARGAS	52
5.1.1. ANÁLISIS DE LAS CARGAS	52
5.1.2. DATOS DE ENTRENAMIENTO DE LAS RNA	57
5.1.3. ENTRENAMIENTO DE LAS RNA.....	63
5.2. SEGUNDO GRUPO DE CARGAS	75
5.2.1. ANÁLISIS DE LAS CARGAS	75
5.2.2. DATOS DE ENTRENAMIENTO DE LAS RNA	82
5.2.3. ENTRENAMIENTO DE LAS RNA.....	86
CAPÍTULO 6.....	100
ANÁLISIS DE LOS RESULTADOS EXPERIMENTALES.....	100
6.1. VALIDACIÓN DEL PRIMER GRUPO DE CARGAS	100

6.1.1. CURVAS DE PRUEBA.....	100
6.1.2. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE EVENTOS	102
6.1.3. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE ESTADOS	105
6.1.4. VALIDACIÓN DEL MODELO TOTAL.....	109
6.2. VALIDACIÓN DEL SEGUNDO GRUPO DE CARGAS	112
6.2.1. CURVAS DE PRUEBA.....	112
6.2.2. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE EVENTOS	113
6.2.3. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE ESTADOS	115
6.2.4. VALIDACIÓN DEL MODELO TOTAL.....	120
CAPÍTULO 7	124
CONCLUSIONES Y TRABAJO FUTURO	124
7.1. CONCLUSIONES.....	124
7.2. TRABAJO FUTURO	126
BIBLIOGRAFÍA	127

LISTA DE FIGURAS

Figura 1. Arquitectura general de una Smart Grid	19
Figura 2. Diagrama de bloques de un sistema basado en eventos	32
Figura 3. Parámetros principales usados en NILM	34
Figura 4. Red neuronal multicapa con alimentación hacia adelante (multilayer feedforward).....	39
Figura 5. Arquitectura de una red de Elman	39
Figura 6. Diagrama de bloques del modelo de monitoreo no intrusivo	46
Figura 7. Estructura de la red neuronal de identificación de eventos.....	48
Figura 8. Estructura de la red neuronal de identificación de estados - caso 2	49
Figura 9. Perfil de potencia activa para entrenamiento.....	57
Figura 10. Perfil de corriente para entrenamiento.....	58
Figura 11. Perfil de impedancia para entrenamiento	59
Figura 12. Perfil de admitancia para entrenamiento	59
Figura 13. Diagrama de flujo del modelo propuesto	63
Figura 14. Porcentaje de acierto redes feedforward y elman con parámetro P - Primer grupo de cargas.....	70
Figura 15. Porcentaje de acierto redes feedforward y elman con parámetros P-Z - Primer grupo de cargas.....	70
Figura 16. Porcentaje de acierto redes feedforward y elman con parámetros P-Y - Primer grupo de cargas.....	71
Figura 17. Porcentaje de acierto redes feedforward y elman con parámetro I - Primer grupo de cargas.....	71
Figura 18. Porcentaje de acierto redes feedforward y elman con parámetros I-Z - Primer grupo de cargas.....	72
Figura 19. Porcentaje de acierto redes feedforward y elman con parámetros I-Y - Primer grupo de cargas.....	72
Figura 20. Porcentaje de acierto red feedforward parámetros P e I - Primer grupo de cargas	73

Figura 21. Porcentaje de acierto red feedforward parámetros P, P-Z y P-Y - Primer grupo de cargas.....	74
Figura 22. Porcentaje de acierto red feedforward parámetros I, I-Z e I-Y - Primer grupo de cargas.....	75
Figura 23. Perfil de consumo de potencia de la carga HPE.....	78
Figura 24. Perfil de consumo de potencia de la carga BME	79
Figura 25. Perfil de consumo de potencia de la carga TVE	80
Figura 26. Perfil de consumo de potencia de la carga DWE.....	81
Figura 27. Perfil de potencia para entrenamiento	83
Figura 28. Perfil de corriente para entrenamiento.....	84
Figura 29. Perfil de impedancia para entrenamiento	85
Figura 30. Perfil de admitancia para entrenamiento	85
Figura 31. Porcentaje de acierto redes feedforward y elman con parámetro P - Segundo grupo de cargas.....	92
Figura 32. Porcentaje de acierto redes feedforward y elman con parámetros P-Z - Segundo grupo de cargas.....	92
Figura 33. Porcentaje de acierto redes feedforward y elman con parámetros P-Y - Segundo grupo de cargas.....	93
Figura 34. Porcentaje de acierto redes feedforward y elman con parámetro I - Segundo grupo de cargas.....	93
Figura 35. Porcentaje de acierto redes feedforward y elman con parámetros I-Z - Segundo grupo de cargas.....	94
Figura 36. Porcentaje de acierto redes feedforward y elman con parámetros I-Y - Segundo grupo de cargas.....	94
Figura 37. Porcentaje de acierto red feedforward parámetros P e I - Segundo grupo de cargas	96
Figura 38. Porcentaje de acierto red feedforward parámetros P-Z e I-Z - Segundo grupo de cargas	97
Figura 39. Porcentaje de acierto red feedforward parámetros P-Y e I-Y - Segundo grupo de cargas	97

Figura 40. Porcentaje de acierto red feedforward parámetros P, P-Z y P-Y - Segundo grupo de cargas.....	98
Figura 41. Porcentaje de acierto red feedforward parámetros I, I-Z e I-Y - Segundo grupo de cargas.....	99
Figura 42. Curva de potencia total de prueba - Primer grupo de cargas	101
Figura 43. Desempeño del entrenamiento y prueba de la RNA 1 - Primer grupo de cargas.....	102
Figura 44. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con P - Primer grupo de cargas	105
Figura 45. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con I - Primer grupo de cargas.....	106
Figura 46. Errores según carga de la red de identificación de estados - Primer grupo de cargas.....	108
Figura 47. Porcentajes de clasificación de eventos en la prueba del modelo total - Primer grupo de cargas.....	110
Figura 48. Errores según carga en la prueba del modelo total - Primer grupo de cargas	111
Figura 49. Curva de potencia total de prueba - Segundo grupo de cargas.....	113
Figura 50. Desempeño del entrenamiento y prueba de la RNA 1 -Segundo grupo de cargas	114
Figura 51. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con P - Segundo grupo de cargas	116
Figura 52. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con I - Segundo grupo de cargas.....	117
Figura 53. Errores según carga de la red de identificación de estados - Segundo grupo de cargas.....	120
Figura 54. Porcentajes de clasificación de eventos con el modelo total - Segundo grupo de cargas	122
Figura 55. Errores según carga del modelo total - Segundo grupo de cargas....	123

LISTA DE TABLAS

Tabla 1. Casos de cambios de estado de las cargas.....	55
Tabla 2. Deltas de potencia mínimos y máximos de las cargas.....	56
Tabla 3. Ejemplo de vectores de entrada para la red de identificación de eventos.....	60
Tabla 4. Valores mínimos y máximos de los parámetros de entrada- Primer grupo de cargas	62
Tabla 5. Entrenamiento de la red de identificación de eventos - Primer grupo de cargas	65
Tabla 6. Entrenamiento de la red feedforward de identificación de estados usando potencia activa - Primer grupo de cargas.....	66
Tabla 7. Entrenamiento de la red feedforward de identificación de estados usando corriente - Primer grupo de cargas	67
Tabla 8. Entrenamiento de la red elman de identificación de estados usando potencia activa - Primer grupo de cargas.....	68
Tabla 9. Entrenamiento de la red elman de identificación de estados usando corriente - Primer grupo de cargas	69
Tabla 10. Mejor porcentaje de acierto red feedforward vs red elman - Primer grupo de cargas	73
Tabla 11. Circuitos de la base de datos AMPds	75
Tabla 12. Coeficiente de correlación entre el consumo de los circuitos y la potencia total de la instalación	76
Tabla 13. Estados de operación de HPE	78
Tabla 14. Estados de operación de BME.....	79
Tabla 15. Estados de operación de TVE	81
Tabla 16. Estados de operación de DWE	82
Tabla 17. Valores mínimos y máximos de los parámetros de entrada- Segundo grupo de cargas	86
Tabla 18. Entrenamiento de la red de identificación de eventos - Segundo grupo de cargas	87

Tabla 19. Entrenamiento de la red feedforward de identificación de estados usando potencia activa - Segundo grupo de cargas	88
Tabla 20. Entrenamiento de la red feedforward de identificación de estados usando corriente - Segundo grupo de cargas	89
Tabla 21. Entrenamiento de la red elman de identificación de estados usando potencia activa - Segundo grupo de cargas.....	90
Tabla 22. Entrenamiento de la red elman de identificación de estados usando corriente - Segundo grupo de cargas.....	91
Tabla 23. Mejor porcentaje de acierto red feedforward vs red elman - Segundo grupo de cargas	95
Tabla 24. Resultados de la prueba de identificación de eventos - Primer grupo de cargas	103
Tabla 25. Matriz de confusión red de identificación de eventos - Primer grupo de cargas	103
Tabla 26. Forma de una matriz de confusión de dos resultados.....	104
Tabla 27. Resultados de la prueba de identificación de estados - Primer grupo de cargas	107
Tabla 28. Matriz de confusión red de identificación de estados - Primer grupo de cargas	108
Tabla 29. Errores según tipo de evento de la red de identificación de estados - Primer grupo de cargas.....	109
Tabla 30. Resultados de la clasificación de eventos del modelo total - Primer grupo de cargas	110
Tabla 31. Matriz de confusión de la prueba del modelo total - Primer grupo de cargas	111
Tabla 32. Errores según tipo de evento del modelo total - Primer grupo de cargas	112
Tabla 33. Resultados de la prueba de identificación de eventos - Segundo grupo de cargas	114

Tabla 34. Matriz de confusión red de identificación de eventos - Segundo grupo de cargas115

Tabla 35. Resultados de la prueba de identificación de estados - Segundo grupo de cargas118

Tabla 36. Matriz de confusión red de identificación de estados - Segundo grupo de cargas119

Tabla 37. Confusiones entre cargas - Segundo grupo de cargas119

Tabla 38. Resultados de la clasificación de eventos del modelo total - Segundo grupo de cargas121

Tabla 39. Matriz de confusión del modelo total - Segundo grupo de cargas122

Tabla 40. Confusiones entre cargas con el modelo total - Segundo grupo de cargas123

CAPÍTULO 1

INTRODUCCIÓN

Los sistemas eléctricos de potencia constituyen una infraestructura de gran complejidad dado que involucran la interacción de un alto número de dispositivos y agentes que deben mantener un equilibrio entre sí. Con el crecimiento de la población y la industria y el desarrollo de nuevas tecnologías, la carga que deben alimentar estas redes también crece. A pesar de esto, la mayoría de las redes eléctricas usadas en la actualidad no han sufrido cambios significativos desde que fueron concebidas hace muchos años atrás, lo cual implica que no han crecido tecnológicamente en varios aspectos y que están siendo sometidas a condiciones para las que no fueron diseñadas.

Tomando en cuenta lo anterior, a nivel mundial han surgido diversas iniciativas para lograr una modernización de los sistemas eléctricos de potencia hacia las denominadas redes inteligentes de electricidad, también conocidas como smart grids. De manera general, estas redes inteligentes involucran el uso de sensores, comunicaciones, control y capacidad computacional para mejorar el funcionamiento general del sistema, lo cual implica un uso más eficiente de la energía, mitigación del impacto ambiental y optimización de costo [1]. En este sentido, la implantación de nuevas herramientas y tecnologías buscan ser aplicadas a lo largo de toda la infraestructura de los sistemas eléctricos, desde la generación hasta los usuarios finales.

Dentro de todas las acciones que deben llevarse a cabo para obtener una red eléctrica inteligente, uno de los aspectos más relevantes es la importancia que cobran los usuarios finales del servicio de energía eléctrica. En las redes tradicionales, estos usuarios son elementos pasivos dentro del sistema ya que no están en la capacidad de interactuar con la red ni identificar formas de hacer un uso más eficiente de la energía. Sin embargo, dentro de una smart grids los usuarios finales buscan convertirse en participantes activos del sistema, de manera que puedan tener la información necesaria para efectuar acciones de eficiencia energética y gestión de la energía, entre otras [2].

Debido a esto, en los últimos años se ha incrementado el interés por el desarrollo de aplicaciones que incentiven la participación activa de la demanda, lo cual genera beneficios tanto para el usuario como para el sistema en general. Se busca que el consumidor tenga alternativas que motiven diferentes patrones y comportamientos en su consumo de energía eléctrica, implicando un uso más eficiente del recurso. Para lograr esto, se necesita de la inclusión de nuevas tecnologías, nueva información acerca del uso de la energía y nuevas formas de tarifas e incentivos [3].

Las nuevas herramientas que se ponen a disposición de los consumidores ante el desarrollo de la tecnología y las redes eléctricas inteligentes incluyen el uso de dispositivos más eficientes, dispositivos inteligentes, control de cargas, tarifas horarias de electricidad, generación distribuida y la instalación de medidores inteligentes, entre otras [4]. Estos últimos dispositivos permiten a los usuarios conocer en tiempo real aspectos generales sobre su consumo de energía eléctrica, lo cual abre paso al desarrollo de aplicaciones para la gestión del consumo a partir de la información proporcionada por los medidores.

Uno de los aspectos más útiles para un usuario final que desea gestionar su energía es conocer de manera detallada que cargas conforman su consumo en cada momento. Esto se puede lograr mediante el uso de sistemas de monitoreo

de cargas, los cuales implican la instalación de dispositivos que constantemente registren el estado de las cargas de una determinada instalación eléctrica. Ante lo complejo que esto puede resultar y las oportunidades proporcionadas en una red eléctrica inteligente, han surgido como alternativa los sistemas de monitoreo no intrusivo de carga (NILM, por sus siglas en inglés) [5]. Estos sistemas permiten conocer los consumos de energía y el patrón de operación de equipos individuales de una instalación eléctrica de manera económica y no intrusiva. Este tipo de sistemas cobran más importancia y crecen sus oportunidades de implementación ante la tendencia creciente de uso de medidores inteligentes en las instalaciones eléctricas.

1.1. PLANTEAMIENTO DEL PROBLEMA

Actualmente, en los sistemas eléctricos de potencia las cargas de los consumidores finales son vistas como un elemento pasivo dentro de estos, lo cual implica que el usuario simplemente consume energía eléctrica de acuerdo a ciertas necesidades y hábitos de consumo, pero no está en la capacidad de interactuar con la red ni identificar formas de hacer un uso más eficiente del recurso.

La mayoría de los usuarios finales de electricidad no poseen información sobre las características principales de su consumo, tales como curvas de carga eléctrica, porcentaje de energía empleada en cada uno de los usos finales y tiempo de uso de los dispositivos eléctricos, entre otras. Esto debido principalmente a que un alto porcentaje de los usuarios del servicio de energía eléctrica, en especial en Latinoamérica, solo cuentan con un medidor de energía convencional a la entrada de sus instalaciones, razón por la cual la única información que conocen es su consumo de energía en un período determinado (por ejemplo kWh/mes), lo cual es

un dato poco específico que no les permite saber de manera detallada que tipo de cargas tienen la mayor influencia sobre dicho consumo. Además, esta información de consumo total de energía durante un tiempo determinado es conocida por el usuario después del período en el cual fue consumida, impidiendo cualquier posibilidad de tomar acciones en tiempo real. Esto implica que el usuario no posee las bases suficientes para evaluar opciones que le permitan emplear más eficientemente la energía eléctrica, ya que no puede identificar aspectos que se puedan mejorar en cuanto a la forma y el momento en el que esta se consume.

Como alternativa para conocer los consumos de energía, parámetros eléctricos y estados de operación de una instalación en particular, se usan los llamados sistemas de monitoreo de cargas. Este tipo de sistemas de monitoreo de cargas tradicionales presenta ciertos inconvenientes, dentro de los que se encuentran el alto costo de instalación de hardware y poca practicidad debido a la necesidad de realizar mediciones constantes sobre cada uno de los dispositivos eléctricos presentes en el área a monitorear. Esto debido a que una instalación eléctrica cuenta con un alto número de circuitos de carga, por lo cual es poco viable contar con equipos de medición que registren los parámetros de cada uno de ellos. Adicionalmente, las cargas pueden ser conectadas en diferentes puntos de la instalación, por lo cual un medidor ubicado en cierto lugar de ella no siempre medirá lo mismo.

Ante los anteriores problemas, los sistemas de monitoreo no intrusivos de carga ofrecen soluciones ya que no requieren una medición de todos los puntos de la instalación, y permiten identificar las cargas presentes en ella sin importar la ubicación. De esta manera, es posible establecer el estado de operación de cada uno de los dispositivos eléctricos presentes en una instalación específica, con lo cual se puede caracterizar en todo momento la curva de consumo general. Así,

resulta de interés diseñar e implementar sistemas de monitoreo que no sean intrusivos, los cuales permitan distinguir consumos individuales a partir de consumos generales suministrados por un medidor inteligente de electricidad.

1.2. OBJETIVOS

- Objetivo General

Desarrollar un modelo de identificación de cargas eléctricas que permita realizar un monitoreo no intrusivo en el marco de una red eléctrica inteligente.

- Objetivos Específicos
- ✓ Realizar un estudio de las cargas eléctricas típicas de la instalación objeto de estudio para identificar estados de operación y características de consumo.
- ✓ Desarrollar un modelo de identificación de cargas eléctricas a partir de consumos globales mediante redes neuronales artificiales.
- ✓ Validar el modelo de identificación de cargas eléctricas desarrollado.

1.3. ALCANCES

- La caracterización de las cargas se realizará a partir de mediciones previas de sus parámetros eléctricos. Estas pueden ser tomadas con un medidor o de bases de datos disponibles.
- Se considerarán cargas típicas de instalaciones de tipo residencial.
- El modelo considera características de estado estacionario de las cargas.

- El modelo de monitoreo no intrusivo desarrollado será de configuración manual y basado en eventos.

1.4. LIMITACIONES

- El modelo desarrollado solo será capaz de identificar en una curva de consumo global las cargas típicas caracterizadas.
- La validación del modelo se realizará con mediciones reales suministradas.

CAPÍTULO 2

REDES ELÉCTRICAS INTELIGENTES

Este capítulo introduce el concepto de redes eléctricas inteligentes, presentando su definición y conceptos fundamentales relacionados con ellas. También se proporciona una visión general sobre los principales trabajos desarrollados en cuanto a esta área.

2.1. DEFINICIONES

2.1.1. SMART GRID

Una smart grid o red eléctrica inteligente es un concepto que busca transformar la red eléctrica de potencia usando técnicas avanzadas de control y comunicación y otras formas de tecnologías de la información, integrando todas estas herramientas desde la generación, transmisión y distribución hasta las cargas de los usuarios [6].

Bajo las anteriores premisas una smart grid puede definirse como una red eléctrica que puede integrar inteligentemente las acciones de todos los agentes conectados a ella, con el fin de entregar eficientemente suministros de electricidad sostenibles, económicos y seguros. Algunos de los objetivos de una red eléctrica inteligente son: [7]

- Facilitar la conexión y operación de generadores de todos los tamaños y tecnologías.
- Permitir a los consumidores jugar un papel importante en la optimización del sistema.
- Proporcionar a los consumidores mayor información y opciones de suministro.
- Reducir significativamente el impacto ambiental de todo el sistema de suministro de energía eléctrica.
- Ofrecer mejores niveles de confiabilidad y seguridad del suministro.

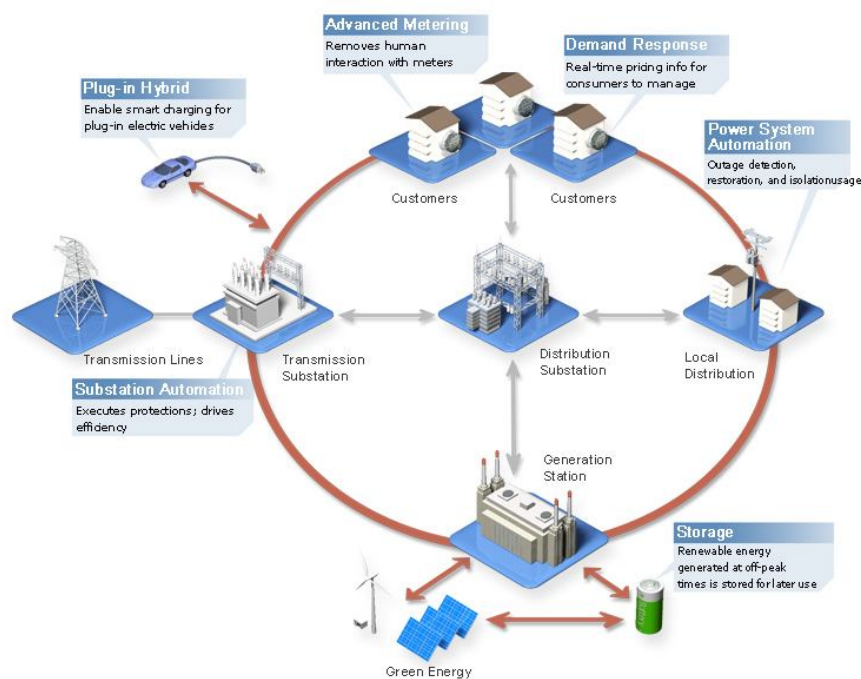


Figura 1. Arquitectura general de una Smart Grid

Fuente: http://www.moxa.com/Solutions/Smart_Grid/. Visitado Enero 29 del 2014.

La figura 1 muestra las principales características que deben tener los diferentes agentes involucrados en el sistema para conformar una red eléctrica inteligente, resaltando la interacción que debe haber entre ellos.

2.1.2 INFRAESTRUCTURA AVANZADA DE MEDICIÓN (AMI)

Uno de los principales objetivos de una smart grid es lograr una mayor inclusión de consumidores en el sistema. Debido a esto, en el desarrollo de una red eléctrica inteligente uno de los primeros avances que deben conseguirse es el despliegue de una infraestructura avanzada de medición (Advanced Metering Infrastructure- AMI), ya que esta abre las puertas al desarrollo de programas, estrategias y aplicaciones para los usuarios finales.

La infraestructura avanzada de medición implica la integración de varias tecnologías que proporcionan una conexión inteligente entre los consumidores y los operadores del sistema. Su implementación da a los usuarios la información que necesitan para tomar decisiones inteligentes, la habilidad para ejecutar dichas decisiones y una variedad de opciones que los llevarían a la obtención de beneficios con los que no cuentan actualmente. Además, a los operadores del sistema les da la capacidad de mejorar notoriamente el servicio al cliente, refinando el funcionamiento del servicio y los procesos de gestión de activos basados en la información proporcionada por la AMI [8].

De manera general, una infraestructura avanzada de medición está compuesta por los siguientes elementos: medidores inteligentes, infraestructura de comunicación de área amplia, redes de área local (HANs) y sistemas de gestión de datos de los medidores (MDMS) [8]. Se identifica como elemento principal el medidor inteligente. Estos dispositivos son medidores de energía avanzados que además de medir el consumo de energía eléctrica de un usuario proporcionan información adicional sobre dicho consumo. Así, pueden leer información del consumo de energía en tiempo real incluyendo los valores de tensión, ángulos de fase y frecuencia y transmitir dicha información de manera segura [9].

Un medidor inteligente está en la capacidad de realizar muchas funciones, dentro de las cuales se encuentran [8]:

- Notificaciones de pérdida y restauración de energía
- Encendido/apagado remoto de operaciones
- Monitoreo de calidad de la energía
- Comunicación con otros dispositivos inteligentes del hogar
- Detección de robo de energía
- Proporcionar datos del consumo a los usuarios y a la compañía prestadora del servicio
- Tarifas horarias

Los medidores inteligentes, junto con una infraestructura de comunicación bidireccional, permiten el desarrollo de aplicaciones que facilitan la inclusión de los usuarios en el sistema y les proporcionan herramientas para hacer una gestión de su energía.

2.1.3. EFICIENCIA ENERGÉTICA

La eficiencia energética se entiende como la utilización de la energía de la manera más rentable para llevar a cabo un proceso o proveer un servicio, de tal forma que se minimice el desperdicio de energía y el consumo general de fuentes primarias de energía sea reducido [10].

A nivel mundial, el uso racional y eficiente de la energía ha sido establecido como un asunto de interés social, público y nacional, especialmente en el uso de la energía eléctrica, debido a las siguientes razones principales: El consumo de energía global está creciendo debido al aumento de la población y uso per cápita de energía; los recursos de combustibles fósiles son finitos, y el costo de extraerlos y usarlos en una forma benigna para el medio ambiente es cada vez más alto; hay una creciente percepción de que el medio ambiente está sufriendo como resultado de la extracción, conversión y uso de los recursos, entre otras [1].

Para lograr una mejor eficiencia energética, las mejoras se refieren a una reducción en la energía usada para una actividad o servicio, lo cual usualmente

está asociado con cambios tecnológicos, mejor administración y organización, y mejores condiciones económicas en el sector. En este sentido, la eficiencia energética es principalmente un asunto de comportamiento individual que refleja la racionalidad de los consumidores de energía. Estos deben evitar tener consumos innecesarios y elegir equipos apropiados, de tal forma que logren disminuir el consumo individual sin disminuir su bienestar [11].

2.1.4. GESTIÓN DE LA DEMANDA

La gestión de la demanda, o DSM por sus siglas en inglés (Demand side management), es un término que abarca actividades sistemáticas diseñadas por las empresas prestadoras del servicio y por el gobierno para cambiar la cantidad y/o el momento del uso de la electricidad por parte del usuario final, para el beneficio colectivo de la sociedad, la empresa prestadora del servicio y sus usuarios [12]. El desarrollo de los conceptos involucrados con la gestión de la demanda fue liderada por el EPRI (Electric Power Research Institute) en los años 1980s, ante la importancia que cobró para las empresas prestadoras del servicio buscar maneras de hacer sus sistemas más eficientes y reducir la necesidad de construir mayores capacidades [13].

Existen seis categorías principales de gestión de la demanda, las cuales son [4]:

- Recorte de picos: Se refiere a control directo de la carga para reducir picos de alto consumo
- Llenado de valles: Se refiere a control directo de la carga para incrementar el consumo durante períodos sin picos
- Desplazamiento de carga: Busca desplazar consumos realizados durante períodos pico a períodos sin pico
- Conservación estratégica: Busca optimizar la curva de carga aplicando métodos de reducción de la demanda, principalmente mejorando la eficiencia en los usos finales

- Crecimiento estratégico de la carga: Se refiere a un incremento general en ventas, estimulado por la empresa prestadora del servicio, más allá del llenado de valles. Se basa en el aumento de la cuota de mercado de cargas apoyado por la conversión de la energía y sistemas de almacenamiento o recursos energéticos descentralizados
- Curva de carga flexible: Está relacionada con problemas de confiabilidad en redes de distribución. Se identifican usuarios con cargas flexibles dispuestos a ser controlados en períodos críticos a cambio de incentivos.

En los programas de gestión de la demanda se deben tener en cuenta tres conceptos: eficiencia energética, conservación de la energía y respuesta de la demanda. La eficiencia energética se refiere a la instalación permanente de tecnologías eficientes y la eliminación de pérdidas de energía; la conservación de la energía implica usar menos de un recurso, usualmente a través de cambios en el comportamiento del consumo; y la respuesta de la demanda se relaciona con el mercado de electricidad y señales de precio para ocasionar una respuesta en los usuarios [14].

Las tecnologías de gestión de la demanda son una pieza fundamental para el desarrollo de las redes eléctricas inteligentes, ya que estas últimas buscan que haya una interacción bidireccional inteligente de información y energía entre el usuario y la red que propicie una participación activa de la demanda. Así, en una red eléctrica inteligente la gestión de la demanda tiene nuevos contenidos tales como automatización de la respuesta de la demanda, consumo inteligente, control remoto de eficiencia energética, entre otros [15].

2.2. ESTADO DEL ARTE EN REDES ELÉCTRICAS INTELIGENTES

En los últimos años se ha incrementado el interés de someter los sistemas eléctricos de potencia a cambios profundos debido a diversas necesidades que se han identificado, tales como: cumplimiento de normas ambientales y conservación de la energía, mayor confiabilidad de la red, mejora de la eficiencia operacional y el servicio al usuario, entre otras. Por lo tanto, las transformaciones que pretenden hacerse a las redes actuales son necesarias para cumplir con los compromisos medioambientales existentes, proveer un mayor énfasis en la respuesta de la demanda y facilitar la generación distribuida [16].

Lograr la modernización de las redes de electricidad en toda su infraestructura y agentes que la componen es una tarea que requiere de un estudio y análisis previo que permitan una posterior implementación exitosa. Siendo consciente de lo anterior y de los beneficios que implica una red inteligente de electricidad, en diversos países se han realizado estudios, investigaciones y pruebas que han representado avances significativos en torno a este tema.

Instituciones reconocidas a nivel internacional se han vinculado a estas iniciativas. Una de ellas es el EPRI (Electric Power Research Institute), el cual es una organización norteamericana que ha enfocado sus esfuerzos desde el año 2001 en una propuesta conocida con el nombre de IntelliGrid. El fin principal de dicha propuesta es crear las bases técnicas necesarias para conseguir una red inteligente que una la electricidad con las comunicaciones y el control computacional, de tal forma que se tengan funcionalidades tales como: visualizar el sistema de potencia en tiempo real, incrementar la capacidad del sistema, aliviar cuellos de botella, tener una red que sea capaz de curarse a sí misma y permitir conectividad con los consumidores, entre otras. Para trabajar en esto se ha creado un consorcio que involucra empresas prestadoras del servicio de electricidad, fabricantes y reguladores que trabajan juntos en conseguir avances que benefician

a todo el sistema. Uno de los desarrollos visibles de la iniciativa es la publicación de un libro guía en el año 2004 llamado The IntelliGrid Architecture, el cual incluye procedimientos detallados para integrar las redes de comunicación y los dispositivos inteligentes esenciales en una Smart Grid, dando información sobre métodos, herramientas y recomendaciones para estructurar los sistemas inteligentes [17].

Dentro de esta arquitectura propuesta se incluye una mayor integración de los consumidores a través de un portal de dos vías llamado EnergyPort, el cual pretende aliviar las restricciones proporcionando tanto una visión del sistema de energía como una manera de interactuar con él. Una de sus características es que posee un conjunto de dispositivos que permiten que los equipos inteligentes presentes en la instalación de un consumidor se comuniquen con sistemas remotos [1].

En el año 2005 se crea también en Estados Unidos una iniciativa conocida con el nombre de The Galvin Initiative, fundada por Robert Galvin. La meta principal de esta iniciativa es definir y lograr el sistema de potencia perfecto, el cual debe ser un sistema enfocado en el consumidor y que nunca falle, es decir, que bajo todas las condiciones sea capaz de cumplir las expectativas de los clientes en cuanto a confiabilidad, conveniencia y opciones [1]. Como reflejo del deseo de The Galvin Initiative de lograr un sistema eléctrico más integrado con los consumidores, confiable y responsable ambientalmente, se establecen una serie de principios para los consumidores de energía eléctrica, los cuales indican que todos los consumidores de energía eléctrica tienen el derecho de: recibir precios dinámicos de electricidad, así como los medios e incentivos para usar esta información a su mayor ventaja; comprar su servicio de electricidad a cualquier fuente que ellos escojan en mercados abiertos y competitivos; tener un sistema de servicio de electricidad confiable y de calidad que proteja la vida y la seguridad bajo todas las condiciones, y cumpla las necesidades de la sociedad digital actual; acceder, en

todo momento, de forma transparente a las métricas de desempeño de su sistema de servicio de electricidad [18].

Muchas otras empresas y organizaciones gubernamentales también han hecho esfuerzos por establecer una visión de las redes inteligentes de electricidad. Como ejemplo de las primeras se encuentra la propuesta realizada por IBM bajo la perspectiva de los consumidores [2], y dentro de las segundas se resalta la desarrollada por el departamento de energía de los Estados Unidos bajo el nombre de The Modern Grid Strategy, la cual hace una descripción en términos de las características y funcionalidades que deben tener las redes de electricidad más que en las tecnologías específicas que deberían ser aplicadas. Así, esta visión establece que las redes deben tener las siguientes características: permitir participación activa de los consumidores; proporcionar todas las opciones de generación y almacenamiento; permitir nuevos servicios, productos y mercados; proporcionar calidad de la energía para la economía digital; optimizar la utilización de los activos y operar eficientemente; anticiparse y responder a las perturbaciones del sistema (auto curación); y operar flexiblemente contra ataques y desastres naturales [19].

Para el caso de Colombia, los acercamientos que se han tenido en torno al desarrollo de redes eléctricas inteligentes se basan principalmente en experiencias con medición inteligente. Sin embargo, solo en algunos sectores específicos se han desarrollado proyectos piloto de este tipo quedando aún mucho camino por recorrer.

Siendo consciente de lo anterior, se ha generado una iniciativa nacional denominada Colombia Inteligente, que busca un desarrollo hacia las nuevas tecnologías y tendencias mundiales [20]. Esta propuesta se estructura con el fin de establecer concertadamente con las principales empresas del sector eléctrico y demás actores relacionados, un marco de lineamientos, políticas y estrategias para el desarrollo óptimo de las redes inteligentes en el sistema eléctrico

colombiano orientado a los retos del país, considerando los beneficios y costos esperados.

Se observa que las iniciativas en torno a una smart grid proponen acciones específicas para lograr una participación activa de los consumidores considerando este punto de vital importancia. Una de las razones por la cual esto sucede es que las necesidades energéticas de los consumidores se mantienen en incremento en la sociedad actual, y ante las avanzadas tecnologías de información y comunicación presentes en las diferentes áreas se ha identificado que los usuarios del servicio de electricidad están interesados en tener opciones en cuanto a quién les suministra dicho servicio y en contar con un control sobre su consumo de energía [2].

2.3. ESTADO DEL ARTE EN INFRAESTRUCTURA AVANZADA DE MEDICIÓN

Dada la tendencia mundial actual de incrementar la participación activa de los usuarios, a nivel mundial se está desarrollando la implementación a gran escala de sistemas de medición inteligente ante las oportunidades que estos ofrecen.

En este sentido, se encuentra que el continente europeo ha sido donde se han realizado mayores esfuerzos por desarrollar e implementar proyectos enfocados en infraestructuras de medición avanzada (AMI) y medidores inteligentes, lográndose en la actualidad la instalación de alrededor de 45 millones de este tipo de medidores a lo largo de todo el continente y proyectando que dicha cifra ascienda a 240 millones para el año 2020. Los países que lideran esta tendencia son Italia, Suecia, Francia, Malta, Finlandia y Reino Unido, siendo el primero el caso más significativo debido a la implementación de un proyecto conocido como Telegestore [21]. Este proyecto italiano es uno de los más grandes que existe a nivel

mundial en cuanto a la implementación de medición inteligente. Fue desarrollado a partir del año 1999 por la compañía de electricidad ENEL (Ente Nazionale per l'Energia Elettrica) con la finalidad de lograr un sistema para manejar los medidores de los usuarios remotamente a través de una red de bajo voltaje, reemplazando así los medidores electromecánicos convencionales con medidores electrónicos inteligentes [22].

Otra iniciativa de importancia es la iniciada en el año 2006 por la empresa Iberdrola conocida con el nombre de PRIME (Powerline Intelligent Metering Evolution). La premisa de esta iniciativa es definir un protocolo abierto con especificaciones libremente distribuibles, es decir, desarrollar una infraestructura AMI de tele gestión de contadores de carácter público, abierto y estándar, y además establecer un conjunto de estándares de ámbito internacional que permita la interoperabilidad entre equipos y sistemas de distintos fabricantes. En la actualidad PRIME se constituye en una alianza industrial en la que de forma voluntaria participan los principales fabricantes de contadores, de equipos de centros de transformación y varias empresas del sector eléctrico. La primera prueba de este concepto se desarrolló en el municipio español Castellón de la Plana, en el cual se instalaron alrededor de 100.000 medidores inteligentes y 600 centros de transformación [23]. Actualmente, la alianza PRIME realiza pruebas y desarrollos en varios países como Brasil, Australia, Portugal y Suiza, entre otros [24].

CAPÍTULO 3

SISTEMAS DE MONITOREO DE CARGAS ELÉCTRICAS

En este capítulo se presentan las definiciones y principales trabajos desarrollados en torno al tema de monitoreo de cargas eléctricas, haciendo énfasis en los sistemas de monitoreo no intrusivos.

3.1. SISTEMA DE MONITOREO INTRUSIVO DE CARGA

Bajo la premisa de que no se puede administrar lo que no se mide, se hace evidente que muchas veces los usuarios finales del servicio de energía eléctrica no tienen la información que necesitan para tomar decisiones fundamentadas y proactivas sobre el uso de la energía. Ante esto, el monitoreo remoto surge como una solución comprobada brindando información, análisis y orientación para ayudar a los usuarios a comprender su uso de la energía, poner en práctica acciones adecuadas y mejorar continuamente la eficiencia energética [25]. En este sentido, un sistema de monitoreo debe indicar donde se está gastando la energía y de qué forma.

De manera general, un sistema de monitoreo de carga tradicional está formado por una red de medidores conectados a un servidor central. Sus elementos

principales son: medidores digitales, red de comunicación, interfaces de comunicación y software o servidor central [26].

Estos sistemas emplean medidores para cada carga monitoreada ya que tienden a ser exhaustivos, sistemáticos y convenientes. Esta gran cantidad de medidores pueden incurrir en tiempo y costos significativos de instalación y mantenimiento, y además pueden afectar la confiabilidad del sistema [27]. Actualmente, muchos de los sistemas disponibles en el mercado son de este tipo, implicando que deben ser conectados directamente a los dispositivos eléctricos. Para su funcionamiento, es necesario que la instalación eléctrica de cada dispositivo sea modificada, razón por la cual este enfoque es conocido como monitoreo intrusivo de carga [28].

Estos sistemas se caracterizan por poseer un hardware complejo y un software simple, ya que este último solo debe recoger y visualizar la información entregada por los medidores. Instalar un sistema de monitoreo tradicional requiere de un esfuerzo considerable y muchas veces resulta impráctico ante el alto número de cargas que deben monitorearse.

3.2. SISTEMA DE MONITOREO NO INTRUSIVO DE CARGA (NILM)

Como una alternativa a las técnicas invasivas de monitoreo, en las últimas décadas ha surgido un enfoque conocido como monitoreo no intrusivo de carga o NILM por sus siglas en inglés (Non Intrusive Load Monitoring). Bajo este enfoque, en lugar de instalar dispositivos de medición en todas las cargas, una sola medición es realizada en el punto principal de la instalación eléctrica [29]. Este consumo general debe ser desagregado de tal forma que pueda ser estimado el consumo de las cargas individuales que lo conforman. En este sentido, el hardware necesario en este tipo de sistemas es simple pero el software es más complejo.

Los sistemas de monitoreo no intrusivo de carga pueden basarse en diferentes técnicas, sin embargo poseen varios principios comunes. En primer lugar, características o firmas de dispositivos específicos deben ser seleccionadas y caracterizadas. Luego, se requiere de una instalación hardware que pueda medir las características seleccionadas, y por último se necesita un algoritmo que detecte dichas características en la señal total medida [30].

3.2.1. CLASIFICACIÓN DE SISTEMAS DE MONITOREO NO INTRUSIVO

Los sistemas de monitoreo no intrusivo de carga se pueden clasificar de acuerdo a dos criterios principales. Uno de ellos está relacionado con el nivel de intrusión en la instalación eléctrica, y el otro con la dependencia o no de la detección de un evento.

De acuerdo con el nivel de intrusión, los sistemas de monitoreo no intrusivo de carga se clasifican de la siguiente manera [31]:

- Configuración manual (MS-NILM): Requiere un período de intrusión para configurar el sistema. Durante este período se realizan mediciones sobre cada carga para observar y establecer las características de cada una de ellas.
- Configuración automática (AS-NILM): Se construye por si solo mientras va midiendo la carga total, utilizando información a priori de las características de las posibles cargas de la instalación.

Los sistemas de configuración manual son más convenientes computacionalmente, sin embargo la recolección inicial intrusiva y la asignación de características hace tedioso el proceso de adaptar nuevos dispositivos.

En el monitoreo de cargas, un evento es definido como un cambio en el nivel de consumo de potencia que está asociado a una transición del estado de operación de una o varias cargas. De acuerdo al uso o no de estos eventos en el proceso de identificación de cargas existen dos tipos de sistemas [32] [33]:

- Basados en eventos (event-based): Se basan en hacer un seguimiento de las transiciones de estado de cada dispositivo, detectando cada evento mediante un algoritmo de identificación aplicado a la curva general de consumo. Las características registradas alrededor del punto donde ocurre un evento son posteriormente clasificadas de acuerdo a un conjunto de reglas empleando métodos de aprendizaje automático. La figura 2 muestra el diagrama de bloques de un sistema de este tipo.

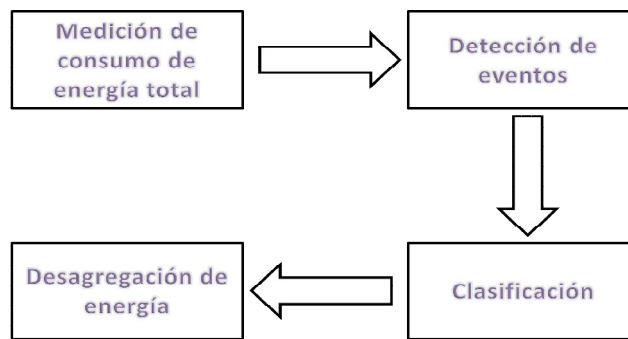


Figura 2. Diagrama de bloques de un sistema basado en eventos

- No basados en eventos (non-event-based): Estos no emplean detección de eventos antes de la clasificación. Por el contrario, intentan separar directamente todas las cargas que conforman la señal de consumo general empleando técnicas como modelos de variables latentes y separación ciega de fuentes.

Los métodos basados en eventos son más eficientes computacionalmente ya que la inferencia y la clasificación solo se necesitan para la identificación de eventos.

3.2.2. ESTUDIO DE CARGAS

Los dispositivos eléctricos presentes en una instalación pueden clasificarse en cuatro categorías de acuerdo a sus características de consumo. Estas categorías son [30]:

- Dispositivos de consumo permanente: Son dispositivos que permanecen encendidos a lo largo de todo el día y tienen un consumo de potencia activa y reactiva aproximadamente permanente.
- Dispositivos encendido/apagado (on-off): Son dispositivos que poseen dos estados, apagado y encendido. La mayoría de las cargas que se encuentran en instalaciones residenciales se encuentran en esta categoría.
- Máquinas de estados finitos (FSM): Esta categoría corresponde a dispositivos que operan a través de varios estados definidos. Existen unas transiciones entre estados específicas para cada dispositivo.
- Dispositivos de consumo continuamente variable: Son dispositivos con consumo de potencia variable que no tienen un patrón periódico de cambio de estados o de nivel de consumo.

Todos los dispositivos eléctricos tienen características específicas en el comportamiento de su consumo de energía, las cuales pueden ser de estado estacionario o de estado transitorio. Por lo tanto, cualquier carga eléctrica puede ser distinguida por sus cambios transitorios, sus niveles de estado estacionario, o una combinación de ambos.

Las características de estado estacionario pueden ser distinguidas con hardware de baja frecuencia. Los principales parámetros eléctricos analizados son: Potencia activa, potencia reactiva, admitancia, corriente y armónicos.

Para detectar las características transitorias se requiere de equipos capaces de realizar muestreos de alta frecuencia, los cuales por lo general tienen un costo mayor a los empleados para medir las características de estado estacionario. El comportamiento transitorio suele ser un indicador confiable para la identificación de cargas, estudiando aspectos como la forma y la duración de los transitorios (por ejemplo tiempos de subida y bajada). Sin embargo, este tipo de análisis presenta algunos inconvenientes, ya que los patrones transitorios de cada carga

deben ser relativamente únicos y razonablemente repetitivos, y además lograr una base de datos de dispositivos es complejo y costoso [5].

La figura 3 muestra los principales parámetros de estado estacionario y estado transitorio que se emplean en el monitoreo no intrusivo de cargas.

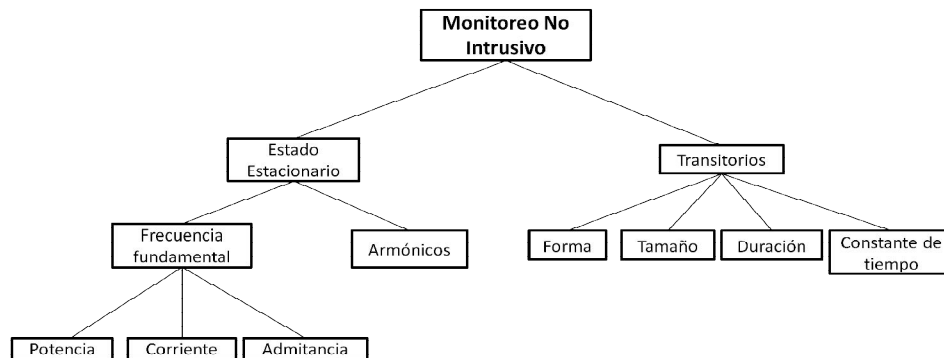


Figura 3. Parámetros principales usados en NILM

3.3. ESTADO DEL ARTE EN SISTEMAS DE MONITOREO NO INTRUSIVO DE CARGA

El monitoreo no intrusivo de carga fue inventado por George Hart, Ed Kern y Fred Schwebpe en los años 1980 con financiamiento del EPRI [34].

Una de las primeras aproximaciones a los sistemas de monitoreo de carga no intrusivos fue desarrollada en el MIT (Massachusetts Institute of Technology), en la cual se determinó el consumo individual de los equipos al encenderse y apagarse con base en la medición de la potencia y tensión en estado estacionario de la carga total, analizando detalladamente la admitancia obtenida [31]. El método propuesto puede detectar cargas de dos estados (apagado/encendido) pero tiene problemas en detectar cargas de múltiples estados y continuamente variables, así como dispositivos con consumos de potencia similares. En esta investigación

también se describen algunos modelos de cargas, huellas de los equipos, algoritmos y prototipos enfocados a monitoreo en edificios residenciales.

En años recientes, uno de los principales incentivos que se ha tenido para el desarrollo de modelos de monitoreo no intrusivo de carga es la creciente implementación de medidores inteligentes, los cuales proporcionan mayor información sobre el consumo total de una instalación. Aprovechando las características de estos medidores, se desarrolló en [35] un sistema de configuración manual que estudia equipos de tipo residencial tomando en cuenta sus huellas de potencia activa y potencia reactiva en estado estacionario, debido a la baja tasa de toma de datos e inhabilidad de detectar transitorios por parte del medidor estudiado. Otros autores han estudiado el uso de estos medidores para la realización de sistemas de monitoreo no intrusivo, como en [36] y [37].

Empleando solo la potencia activa, se plantea en [38] un sistema capaz de desagregar la potencia activa total para obtener información específica de los equipos en instalaciones residenciales, lo cual se hace a través de la detección de cambios escalonados en el consumo de potencia activa total mediante un modelo de optimización simple. Para poder hacer dicha descomposición se modela cada equipo estudiado y sus características de carga solo de acuerdo a su perfil de consumo de potencia activa. En este caso solo se consideran equipos de dos estados, apagado y encendido. Este sistema presentó limitaciones en la identificación de ciertas cargas, por lo cual los resultados arrojaron que el 42% de la energía total consumida en la instalación residencial estudiada no podía ser detectada. Otra investigación considera como característica la potencia activa junto con reglas de decisiones específicas para cada dispositivo de altos consumos de potencia [39]. Este método alcanzó una precisión de detección estimada del 80%, sin embargo requiere de un tiempo de entrenamiento excesivo y la necesidad de reglas específicas para cada carga lo hace poco atractivo.

Otro de los parámetros que puede ser usado para el desarrollo de modelos es el contenido de armónicos de las señales. Así, por ejemplo, en [40] se emplea el reconocimiento de patrones de armónicos aplicado en edificios comerciales. Para esto, se toman medidas de patrones de armónicos considerando corrientes armónicas impares, desde el armónico 1 hasta el 13, y la diferencia de fase de cada una de estas corrientes respecto a la tensión fundamental. Los patrones de armónicos son introducidos en una SVM (support vector machine) y una red de función de base radial (RBFN) para inferir el estado de operación (encendido/apagado) de cada dispositivo eléctrico conectado aguas abajo del punto de medida. En [41] se probaron varias técnicas basadas en la extracción de características importantes de la forma de onda de la corriente de entrada para identificar varios tipos de dispositivos usando sus huellas de armónicos distintivas. De esta manera, la distorsión de la forma de onda causada por cargas no lineales se cuantificó en el dominio de la frecuencia aplicando el análisis de Fourier, y se usó para detectar de manera no intrusiva la presencia de varios dispositivos dentro de una instalación. Se obtuvo un porcentaje de detecciones acertadas entre el 80 y 90%.

Otros autores han optado por estudiar las características transitorias de las cargas. Así, en [48] se emplean los transitorios de encendido y apagado de cargas analizando la naturaleza de la variación de estos. Se emplea un algoritmo de reconocimiento de patrones, que compara los transitorios con una base de datos previamente obtenida de dispositivos, para establecer que carga fue encendida o apagada. El algoritmo fue probado en algunas formas de onda obteniéndose resultados satisfactorios. Los autores de [43] extrajeron trece características de una forma de onda transitoria de corriente, tales como el factor de forma, el valor máximo y la energía transitoria. Fueron escogidas las características más óptimas para la identificación de cargas mediante algoritmos genéticos con criterio de Fisher. Posteriormente se aplicaron diferentes métodos de identificación obteniéndose porcentajes de reconocimiento entre 85% y 98%.

En cuanto al desarrollo de los algoritmos de identificación de cargas pueden emplearse diversas técnicas. Algunos autores han trabajado con modelos ocultos de Markov [44] y series de tiempo [45] para el desarrollo de sistemas no basados en eventos. Para los sistemas basados en eventos se han usado modelos de redes neuronales artificiales, LVQ (Learning Vector Quantization) [46] , k-NN (k-Nearest- Neighbor) [47], SVM (Support Vector Machine) [48] y métodos probabilísticos [49], entre otros.

Las redes neuronales artificiales se han identificado como una técnica de inteligencia artificial que puede ser exitosamente aplicada en el monitoreo no intrusivo de cargas. A continuación se profundiza sobre esto.

3.3.1. REDES NEURONALES ARTIFICIALES (RNA) Y SU APLICACIÓN EN EL MONITOREO NO INTRUSIVO

La inteligencia artificial se define como la inteligencia exhibida por una entidad artificial para resolver problemas complejos y dicho sistema generalmente se asume que es un computador o una máquina [50].

Las redes neuronales artificiales son una rama de la inteligencia artificial que se han desarrollado como generalizaciones de modelos matemáticos de sistemas nerviosos biológicos [51]. Estas redes son estructuras de mapeo no lineales basadas en la función del cerebro humano y constituyen una herramienta poderosa para el modelado, especialmente cuando la relación de datos subyacente es desconocida. De esta manera, las redes neuronales artificiales pueden identificar y aprender patrones correlacionados entre conjuntos de datos de entrada y sus correspondientes valores objetivos [52].

Una red neuronal artificial posee tres tipos de capas en su estructura. La primera es la capa de entrada, la cual interactúa directamente con el exterior obteniendo los datos de entrada; la segunda es la capa oculta, donde se realiza la computación de acuerdo a las funciones establecidas; y la última es la capa de

salida de la cual se obtiene el resultado de la red [51]. Para obtener los resultados de salida las redes neuronales usan funciones de activación, las cuales son fórmulas matemáticas que determinan la salida de un nodo.

El desarrollo de una RNA comprende tres etapas principales: diseño de la arquitectura, entrenamiento y validación. En la fase de diseño se determina el número de neuronas que tendrá la red, incluyendo su disposición en capas y la conectividad entre ellas, la topología de la red y las funciones de activación y transferencia. La fase de entrenamiento se realiza con el fin de que la red aprenda a dar la respuesta adecuada a la configuración de estímulos o patrones de entrada que se le presente. Durante la fase final de validación se mide la respuesta de la red ante estímulos diferentes a los presentados durante la fase de entrenamiento, ya que la red debe estar en la capacidad de generalizar y dar respuestas correctas ante nuevos patrones de entrada [53]

Existen diferentes tipos de arquitectura para una red neuronal artificial. Los dos tipos más usados son:

- Redes alimentadas hacia adelante (feedforward): En este tipo de redes la información es transmitida hacia adelante desde la capa de entrada, pasando por las capas ocultas (si las hay) para finalmente ser procesada por la capa de salida. Se resalta que no hay ningún lazo o retroalimentación [54]. La figura 4 muestra la arquitectura de una red neuronal multicapa con alimentación hacia adelante.




Figura 4. Red neuronal multicapa con alimentación hacia adelante (multilayer feedforward)

- Redes recurrentes: Estas redes pueden tener señales viajando en ambas direcciones al introducir al menos un bucle o retroalimentación en su estructura. Esto les permite hacer procesamiento temporal y aprender secuencias. Existen redes totalmente recurrentes, las cuales tienen caminos de retroalimentación en todos los elementos que la conforman teniendo una alta complejidad, y existen redes parcialmente recurrentes las cuales poseen algunas retroalimentaciones. Un ejemplo de estas últimas son las redes de Elman, las cuales están constituidas por una capa de entrada, dos capas intermedias (oculta y de contexto) y una capa de salida [55], como se observa en la figura 5.




Figura 5. Arquitectura de una red de Elman

Las redes neuronales artificiales son uno de los métodos que suelen emplearse para el desarrollo de sistemas de monitoreo no intrusivo de carga. En [56] se emplean dos tipos de redes, una multicapa de alimentación hacia adelante con algoritmo de retropropagación y una Elman, para calcular el porcentaje de consumo de cada carga sobre el consumo total empleando como parámetro de entrada el espectro de armónicos. Para el primer tipo de red se obtuvo un porcentaje de error promedio del 10%, mientras que para el segundo tipo fue del 22%. Otra comparación, entre un perceptrón multicapa y una red RBF (función de base radial), fue realizada en [41] empleando como entrada a las redes los componentes armónicos de la corriente en estado estable. En el reconocimiento de la presencia o ausencia de 10 dispositivos en la señal de consumo total se obtuvieron porcentajes de acierto entre el 70 y el 100%, dependiendo del dispositivo. En términos generales, el perceptrón multicapa presentó un mejor desempeño.

Una red Adaline fue desarrollada en [37] usando los 50 primeros períodos de la potencia aparente de las cargas para detectar sus cambios de estado. Este método fue diseñado para cargas presentes en instalaciones residenciales pero solo fue probado con un refrigerador.

Haciendo uso de características tanto de estado estacionario como de estado transitorio se desarrolló en [57] un método que buscaba mejorar la precisión y la velocidad computacional en el monitoreo no intrusivo. Así, se emplearon los parámetros de potencia activa, potencia reactiva y energía transitoria de encendido para desarrollar una red multicapa de realimentación hacia adelante para identificar tres cargas de dos estados obteniéndose resultados satisfactorios.

Otros autores, como en [46] y [49], han desarrollado métodos de monitoreo no intrusivo mediante redes neuronales artificiales pero no han proporcionado información suficiente sobre las características de las redes empleadas.

CAPÍTULO 4

DEFINICIÓN DEL MODELO DE MONITOREO NO INTRUSIVO DE CARGA

En este capítulo se establecen los grupos de cargas eléctricas que serán objeto de estudio y se estructura el modelo de monitoreo no intrusivo que será desarrollado, identificando sus principales características.

4.1. ESTUDIO DE CARGAS ELÉCTRICAS

Todas las instalaciones eléctricas están conformadas por una serie de cargas, cada una de las cuales posee un comportamiento específico. Los diferentes tipos de edificaciones que existen (por ejemplo, residenciales, comerciales e industriales) suelen estar conformadas por cargas diferentes. Sin embargo, dentro de edificaciones del mismo tipo existen cargas que por lo general están siempre presentes y, por lo tanto, son consideradas cargas típicas.

En una instalación de tipo residencial suelen encontrarse dispositivos tales como bombilla, televisor, plancha, licuadora, computador, nevera, lavadora, ventilador, aire acondicionado, calefacción y sanduchera, entre otros. El primer paso para el desarrollo de un modelo de monitoreo no intrusivo es identificar las cargas que

serán caracterizadas, de tal forma que estas puedan ser identificadas a partir de consumos totales.

Una vez se establecen las cargas a caracterizar, se procede a identificar sus estados de operación y a determinar el comportamiento de su consumo de energía en cada uno de ellos. Esto último se logra mediante el análisis de mediciones realizadas sobre las cargas. Suelen analizarse parámetros como potencia activa, potencia reactiva, potencia aparente, corriente y admitancia.

Para el desarrollo del modelo propuesto en esta investigación, se utilizarán dos conjuntos diferentes de cuatro cargas típicas de instalaciones residenciales. El primer grupo está conformado por cargas medidas en condiciones de laboratorio, mientras el segundo se obtiene de una base de datos disponible en internet, la cual contiene mediciones de los circuitos de un hogar durante un período determinado de tiempo.

4.1.1. PRIMER GRUPO DE CARGAS

Este grupo está conformado por cuatro dispositivos eléctricos sobre los cuales se realizan mediciones mediante un sistema dispuesto para tal fin.

Las cuatro cargas seleccionadas son de dos estados (encendido/apagado) y se pueden encontrar típicamente en una instalación residencial. Estas cargas y sus consumos nominales de potencia son:

- Plancha: 1200 W
- Ventilador: 140 W
- Licuadora: 240 W
- Sanduchera: 660 W

Estas cargas se seleccionan dado su común uso en el plano doméstico. Además, estas poseen niveles de consumo de potencia diferente y características diferentes, ya que dos son predominantemente resistivas (plancha y sanduchera) y dos son predominantemente inductivas (ventilador y licuadora).

Las mediciones fueron realizadas con un medidor comercial marca Electro Industries/GaugeTech modelo Shark® de referencia 200s. La información adquirida por este medidor fue enviada y almacenada en un computador mediante una red de comunicación inalámbrica con radiotransmisores de tecnología ZigBee.

Los parámetros registrados por el sistema son: Tensión, corriente, potencia real, potencia reactiva, potencia aparente, factor de potencia y frecuencia. La frecuencia de muestreo fue de 0,5 Hz, es decir, se tomaron medidas cada 2 segundos.

Para la obtención de las características de apagado y encendido de las cargas fue necesario diseñar y construir un módulo que permitiera la conexión de estas con el medidor Shark y una fuente de generación variable de referencia DL 1013. Dicho módulo consta de 2 tomacorrientes dobles para conectar las cuatro cargas, una protección eléctrica, un punto de conexión con la fuente AC, y el arreglo de conductores necesario.

4.1.2. SEGUNDO GRUPO DE CARGAS

El segundo grupo de cargas está conformado por mediciones consignadas en bases de datos en la web, que han sido reportadas en informes y artículos por diferentes investigadores.

En los trabajos realizados a nivel mundial sobre monitoreo no intrusivo, se ha observado que los principales esfuerzos de investigación han estado más enfocados hacia la exploración de las características de las cargas que hacia el desarrollo de algoritmos [30]. Ante esto, muchos investigadores han empezado a publicar sus bases de datos de mediciones para facilitar la labor de otros investigadores y promover el desarrollo de algoritmos, ya que la recolección de las medidas para el desarrollo de sistemas de monitoreo no intrusivo requiere de bastante tiempo y suele ser costosa.

Dentro de estas bases de datos se encuentra una desarrollada en el MIT conocida con el nombre de REDD (Reference Energy Disaggregation Data Set) [58], la cual

contiene información detallada del uso de energía eléctrica de seis hogares ubicados en Estados Unidos con el fin de promover la investigación en desagregación de energía. REDD fue principalmente creada para la evaluación de métodos de monitoreo no intrusivo no basados en eventos.

En esta base de datos, se encuentran medidas del consumo de todo el hogar y de circuitos y aparatos específicos en casas reales durante un período de varios meses. Cada casa tiene dos entradas principales bifásicas y entre 10 y 25 circuitos individuales. La base de datos contiene la siguiente información:

- Potencia activa de los dos circuitos principales medida cada segundo.
- Potencia activa de los circuitos individuales medida cada 3 segundos.
- Medición de alta frecuencia de la forma de onda de corriente de los circuitos principales.
- Medición de alta frecuencia de la forma de onda de tensión de una fase.

Por otro lado, la base de datos BLUED (Building-Level fUlly labeled Electricity Disaggregation dataset) fue principalmente desarrollada para el uso en métodos basados en eventos. Esta base de datos contiene mediciones de alta frecuencia (12 kHz) de tensión y corriente de un solo hogar en los Estados Unidos durante un período de una semana [33]. Cada transición de estado de cada dispositivo en el hogar fue etiquetada para facilitar la evaluación de algoritmos basados en eventos.

Los autores de [59] crearon un repositorio de dispositivos eléctricos llamado Tracebase. En este, se midieron por separado distintas cargas registrando sus consumos de potencia activa en intervalos de un segundo. No se realizaron medidas de consumos totales compuestos por varias cargas.

Existen otras bases de datos las cuales a pesar de no ser especialmente desarrolladas para los modelos de desagregación de energía también sirven para estos fines. Tal es el caso del proyecto Smart* desarrollado por la Universidad de Massachusetts [60], el cual incluye la recopilación del uso promedio de

electricidad de los hogares, datos de generación de energía eléctrica a partir de paneles solares o turbinas de viento, información de las condiciones climáticas exteriores, datos de temperatura y humedad al interior del hogar y datos de eventos de encendido/apagado relevantes. En cuanto al consumo eléctrico total y de los circuitos individuales se proporcionan la potencia activa y la potencia aparente.

Como se observa, la mayoría de las bases de datos disponibles no presentan una información del consumo de energía completa o presentan mediciones durante períodos cortos de tiempo, lo cual puede resultar insuficiente para el desarrollo de algoritmos de desagregación de carga. Ante esto, una alternativa interesante es la base de datos presentada en [61], la cual recibe el nombre de AMPds (Almanac of Minutely Power dataset). Esta contiene mediciones durante un año de 11 parámetros eléctricos para 21 circuitos que conforman un hogar específico, ubicado en Vancouver (Canadá), incluyendo consumos individuales y agregados. En intervalos de un minuto se registran la tensión, corriente, frecuencia, factor de potencia, potencia real, potencia reactiva y potencia aparente, entre otros parámetros.

De acuerdo a lo anteriormente expuesto y teniendo en cuenta que el modelo desarrollado en la presente investigación será basado en eventos, se selecciona la base de datos AMPds como fuente para el segundo grupo de cargas con las cuales se desarrollará el modelo.

4.2. ESTRUCTURA DEL MODELO DE MONITOREO NO INTRUSIVO

La estructura general del modelo de monitoreo no intrusivo propuesto se muestra en la figura 6. En este diagrama de bloques se observa que, en primera instancia, se debe obtener la curva general de consumo de la instalación, la cual es la suma

del conjunto de consumos de todas las cargas presentes en esta. En una instalación eléctrica con n cargas, la potencia total en cualquier instante, $P_t(t)$, es:

$$P_t(t) = \sum_{i=1}^n P_i(t) \quad (1)$$

La curva de potencia total presenta cambios significativos cuando los dispositivos eléctricos cambian su estado de operación. Estos cambios son de vital importancia, por lo cual en cada instante se analiza el comportamiento de la curva total de tal forma que se pueda hacer una identificación de eventos, los cuales corresponden a cambios en estados de operación de los equipos eléctricos. Esto se expresa matemáticamente en la ecuación (2).

$$dP_t(t) = \sum_{i=1}^n dP_i(t) \quad (2)$$

Donde $dP_t(t)$ es el delta de potencia de curva total y $dP_i(t)$ es el delta de potencia de cada carga.

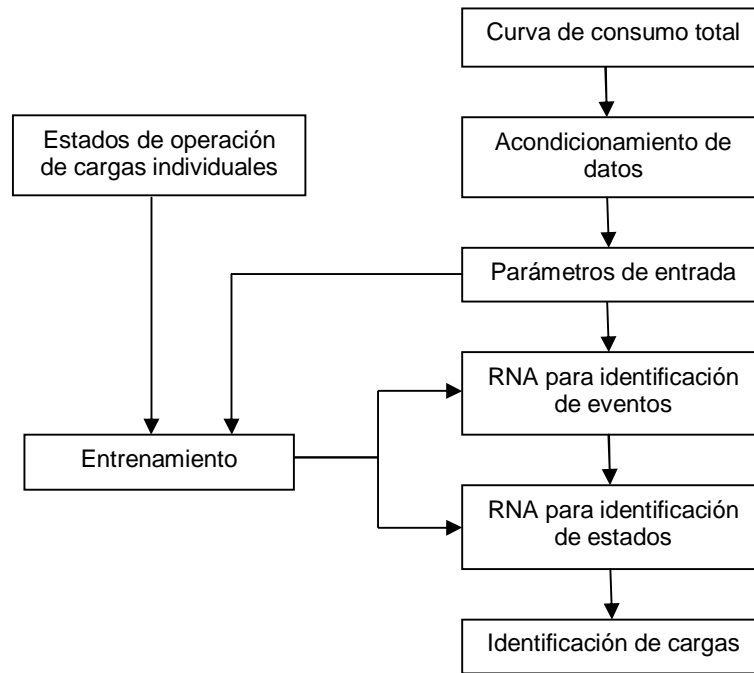


Figura 6. Diagrama de bloques del modelo de monitoreo no intrusivo

Para identificar los eventos, generalmente se establece un valor de delta de potencia mínimo. Cuando este límite es superado se dice que una o más cargas cambiaron su estado de operación. Este método resulta ser sencillo pero puede ser poco eficaz, sobre todo cuando las cargas presentan algunas variaciones en su consumo de potencia, las cuales pueden superar el delta de potencia mínimo sin implicar un cambio de estado.

Ante lo anterior, se propone el uso de una red neuronal artificial para la identificación de eventos. De esta manera, se establece un delta de potencia mínimo con el cual se analizará la curva total. Aquellos puntos que superen este delta serán introducidos a la red neuronal, la cual determinará si corresponden o no a un evento.

Luego de la identificación de un evento, se procede a determinar los dispositivos que cambiaron su estado de operación mediante el uso de otra red neuronal artificial. Para ello, es necesario establecer los parámetros de la curva total que serán usados como datos de entrada a la red, de tal forma que se realice un entrenamiento previo empleando estos datos junto con el conocimiento de los estados de operación de las cargas individuales. Este entrenamiento solo se realiza una vez cuando se está desarrollando el modelo. Luego de esto, la red debe estar en la capacidad de identificar en qué estado se encuentra cada carga a partir del ingreso de los parámetros seleccionados de la curva de consumo total. Con esto, se podrá saber que dispositivos inciden en cada momento en el consumo total de energía eléctrica de la instalación. Cabe destacar que la red de identificación de eventos también debe entrenarse de acuerdo a los parámetros de entrada establecidos.

4.2.1. ESTRUCTURA DE LAS REDES NEURONALES ARTIFICIALES

Como se observó anteriormente, se emplearán dos redes neuronales para el análisis de una curva de consumo total. La primera red que se empleará será llamada de aquí en adelante red de identificación de eventos. Como su nombre lo indica, esta será empleada para identificar los eventos en la curva de consumo total. Su entrada será el valor de la potencia activa durante y en el instante anterior de la ocurrencia de un posible evento y tendrá una sola salida que podrá tomar los valores de -1 y 1. Si la salida es 1 indica que se está en la presencia de un evento, mientras que si es -1 indica que no se está en la presencia de un evento. La estructura se observa en la Figura 7. Estructura de la red neuronal de identificación de eventos. En esta, $P_t(t-1)$ y $P_t(t)$ son la potencia activa total antes y durante un posible evento, respectivamente.




Figura 7. Estructura de la red neuronal de identificación de eventos

Cuando en la curva de consumo total se identifica que ha ocurrido un evento, es decir, cuando la salida de la red de identificación de eventos es 1, la segunda red neuronal debe establecer el estado de cada dispositivo antes y después del instante en que ocurre este cambio. Esta red será llamada red I de identificación de estados.

La potencia activa es un parámetro ampliamente usado en los modelos de caracterización de cargas, pero por sí sola puede resultar insuficiente para generar resultados positivos altos. En la búsqueda de otro parámetro que permita optimizar estos modelos, se propone la exploración del uso de la impedancia y la admitancia como complemento de la potencia activa. Se propone también el uso de estos

parámetros como complemento de la corriente, en lugar de la potencia activa. De esta forma, se utilizarán los siguientes conjuntos de parámetros como entradas de la red neuronal de identificación de estados:

1. P
2. P-Z
3. P-Y
4. I
5. I-Z
6. I-Y

Como se observa, en primer lugar se empleará solo la potencia activa (P) como parámetro de entrada. Luego, esta se combinará con la impedancia (Z) y la admitancia (Y). Lo mismo se realizará con la corriente (I).

De acuerdo con los parámetros de entrada considerados, la red de identificación de estados tendrá 2 o 4 entradas y 8 salidas. En la Figura 8. Estructura de la red neuronal de identificación de estados - caso se observa la estructura de la red para el caso 2, en el cual las entradas son P y Z, aplicado al primer grupo de cargas. Análogamente se desarrollan los demás casos.

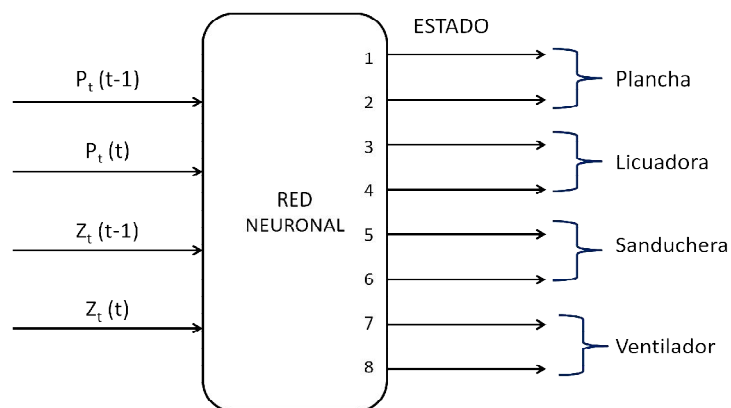


Figura 8. Estructura de la red neuronal de identificación de estados - caso 2

El instante t es aquel en el cual se ha identificado la ocurrencia de un evento. Ante esto, los parámetros de entrada a la red serán los valores de potencia activa total e impedancia total, tanto en el instante en el que ocurrió el evento ($P_t(t)$ y $Z_t(t)$) como en el instante anterior ($P_t(t-1)$ y $Z_t(t-1)$). Esto debido a que con estos datos la red está en la capacidad de establecer relaciones entre los niveles de potencia e impedancia total, sus cambios y el estado de cada uno de los equipos de la instalación.

La red presenta ocho salidas las cuales corresponden al estado de cada dispositivo antes y después de la ocurrencia de un evento. De la Figura 8. Estructura de la red neuronal de identificación de estados - caso 2, se puede observar que para este grupo de cargas las salidas 1 y 2 están asociadas a la plancha, las 3 y 4 a la licuadora, las 5 y 6 a la sanduchera, y las 7 y 8 al ventilador. De esta forma, la salida impar de cada equipo corresponde al estado de este antes del evento y la salida par al estado después del evento. Estas salidas podrán tomar valores enteros entre 1 y 8, cada uno de los cuales corresponde a un estado de operación específico, de la siguiente manera:

1. Plancha apagada
2. Plancha encendida
3. Licuadora apagada
4. Licuadora encendida
5. Sanduchera apagada
6. Sanduchera encendida
7. Ventilador apagado
8. Ventilador encendido

La estructura de la red de identificación de eventos será aplicada a una red multicapa con alimentación hacia adelante. Por otro lado, para la red de identificación de estados se aplicarán dos arquitecturas diferentes, las cuales son: una red multicapa con alimentación hacia adelante y algoritmo de retro

propagación (feedforward backpropagation), y una red Elman. Esto con el fin de determinar el comportamiento de redes sin realimentación y con realimentación en la solución de problemas de monitoreo no intrusivo de cargas. Todas las redes empleadas tendrán una capa oculta de neuronas.

CAPÍTULO 5

DESARROLLO DEL MODELO DE MONITOREO NO INTRUSIVO DE CARGA

Este capítulo presenta el análisis de los dos grupos de cargas establecidos y la implementación del modelo propuesto para cada uno de ellos. Se muestra el entrenamiento realizado sobre las redes neuronales y se analiza la incidencia de cada conjunto de parámetros de entrada sobre la identificación de las cargas.

5.1. PRIMER GRUPO DE CARGAS

5.1.1. ANÁLISIS DE LAS CARGAS

Para las cuatro cargas que conforman este grupo, se pueden presentar varias combinaciones de cambios de estado de operación. Para establecer cuáles son estas combinaciones, se tiene en cuenta que un evento representa un cambio en el estado de operación de una o más cargas. De acuerdo al número de cargas que cambian su estado de operación simultáneamente, se definen cuatro tipos de eventos, los cuales son:

a. Evento tipo 1

Se define este tipo de evento como aquel en el cual una sola carga cambia de estado de operación. Esto implica que el cambio en la curva de potencia total es

causado por una sola carga, ya que las otras tres se mantienen en un mismo estado de operación.

Dado que se tienen cuatro cargas y cada una de estas tiene dos estados de operación, el número de combinaciones de cambios de estado posible es:

$$n_1 = 4 \times 2 = 8 \quad (3)$$

Donde n_1 es el número de combinaciones posibles cuando una sola carga cambia de estado de operación.

b. Evento tipo 2

Para este tipo de evento, el cambio en la potencia total es causado por dos cargas que cambian de estado de operación al mismo tiempo, mientras las otras dos se mantienen en un mismo estado.

Teniendo en cuenta que se seleccionan 2 de las 4 cargas sin importar el orden, se aplica una combinación sin repetición, c , en la cual:

$$c = \binom{x}{r} \quad (4)$$

Donde x es el número de elementos que se pueden elegir y r es el número de elementos que se eligen. Por lo tanto: $c = \binom{4}{2} = 6$

$$c = \binom{4}{2} = 6 \quad (5)$$

A su vez, cada una de las 6 combinaciones de 2 cargas tiene $\binom{2}{1} \times \binom{2}{1}$ opciones de cambio, ya que cada carga tiene 2 estados y cualquiera de los dos puede estar operando. Por lo tanto, el número de combinaciones totales que existen para este caso es:

$$n_2 = \binom{4}{2} x \binom{2}{1} x \binom{2}{1} = 24 \quad (6)$$

Lo anterior quiere decir que existen 24 formas de que dos cargas, de las cuatro existentes, cambien de estado de operación a la vez.

c. Evento tipo 3

En un evento de este tipo, tres cargas cambian de estado de operación simultáneamente y una se mantiene en el mismo estado.

Empleando un razonamiento análogo al anterior, el número de combinaciones que existen cuando tres cargas cambian de estado de operación al mismo tiempo es:

$$n_3 = \binom{4}{3} x \binom{2}{1} x \binom{2}{1} x \binom{2}{1} = 32 \quad (7)$$

d. Evento tipo 4

Este tipo de evento se presenta cuando todas las cuatro cargas cambian su estado de operación al mismo tiempo. Por lo tanto, el cambio en la potencia total es un reflejo de la acción de todas las cargas.

En este caso, el número de combinaciones posibles es:

$$n_4 = \binom{4}{4} x \binom{2}{1} x \binom{2}{1} x \binom{2}{1} x \binom{2}{1} = 16 \quad (8)$$

El número total de combinaciones que existen, tomando en cuenta todos los casos posibles expuestos, es:

$$n = n_1 + n_2 + n_3 + n_4 = 8 + 24 + 32 + 16 = 80 \quad (9)$$

Los casos correspondientes a las anteriores combinaciones se muestran en la tabla 1. En esta, se observan las combinaciones de las cargas que pueden cambiar para cada caso y los estados que estas pueden tomar.

De aquí en adelante se entenderá que las cargas A, B, C y D corresponden a la plancha, licuadora, sanduchera y ventilador, respectivamente.

Tabla 1. Casos de cambios de estado de las cargas

Evento tipo 1	Combinaciones de carga	A	B	C	D
	Estados	on	off		
Evento tipo 2	Combinaciones de carga	AB	AC	AD	BC
		BD	CD		
	Estados	on-on	off-off	on-off	off-on
Evento tipo 3	Combinaciones de carga	ABC	ABD	ACD	BCD
	Estados	on-on-on	off-off-off	on-off-off	on-on-off
		on-off-on	off-on-on	off-off-on	off-on-off
Evento tipo 4	Combinaciones de carga	ABCD			
	Estados	on-on-on-on	on-on-on-off	on-on-off-on	on-off-on-on
		on-on-off-off	on-off-off-on	on-off-on-off	on-off-off-off
		off-on-on-on	off-on-on-off	off-on-off-on	off-off-on-on
		off-on-off-off	off-off-off-on	off-off-on-off	off-off-off-off

Para las cargas en cuestión se realizaron mediciones sobre:

- Las cargas individuales
- Dos cargas encendiendo y apagando al mismo tiempo
- Tres cargas encendiendo y apagando al mismo tiempo
- Todas las cargas encendiendo y apagando al mismo tiempo
- Conjuntos de dos y tres cargas encendiendo y apagando secuencialmente.

Como se observa, algunos de los casos existentes fueron medidos directamente. Dado que el número de casos es alto y que aumenta a medida que se adicionan

más cargas, los demás casos pueden obtenerse a partir de las mediciones realizadas sobre las cargas.

Con base en las medidas registradas, se obtuvieron los valores máximos y mínimos del delta de potencia que ocurre cuando las cargas se encienden y se apagan, los cuales se observan en la tabla 2.

Tabla 2. Deltas de potencia mínimos y máximos de las cargas

	dP [W]			
	on		off	
	min	max	min	max
A	1194,63	1227,92	-1194,35	-1225,15
B	158,365	293,115	-158,786	-227,213
C	665,071	674,026	-663,969	-685,258
D	83,4094	139,048	-88,3735	-121,867

Realizando un análisis de los valores de la tabla 2, es posible establecer que el mínimo delta de potencia que se presenta por cambio de estado de los equipos se da cuando el ventilador se enciende con su valor más alto, y la licuadora se apaga con su valor más bajo. En este caso:

$$d_p = |139,048 - 158,786| = 19,738 \quad (10)$$

Esto quiere decir que esta combinación de cambios de estados se ve reflejada en la curva de consumo total con un decremento de 19,738 W.

Con base en lo anterior, el delta mínimo de potencia para identificación de eventos se establece en 19 W. Así, todos los cambios de potencia en la curva total que sean mayores a 19 W serán ingresados en la red de identificación de eventos.

5.1.2. DATOS DE ENTRENAMIENTO DE LAS RNA

Para desarrollar las redes neuronales artificiales, se creó una curva de consumo de energía para entrenamiento con base en las mediciones realizadas sobre las cargas. En el desarrollo de esta curva, se incluyeron todas las combinaciones posibles de cambios de estados de operación determinadas, de tal forma que los datos fueran representativos. Así, se creó una curva de consumo total de energía de una duración de 1 hora, 44 minutos y 52 segundos, en la cual se incluyeron 618 eventos.

La Figura 9 y la Figura 10 muestran el perfil de consumo de potencia activa y el perfil de corriente de la curva de entrenamiento, respectivamente.




Figura 9. Perfil de potencia activa para entrenamiento




Figura 10. Perfil de corriente para entrenamiento

A partir de los parámetros eléctricos registrados, es posible calcular los valores de impedancia total y admitancia total en todo momento, de acuerdo a las ecuaciones:

$$Z = \frac{S}{I^2} ; Y = \frac{1}{Z} \quad (11)$$

De esta forma, se obtiene el perfil de impedancia mostrado en la Figura 11 y el perfil de admitancia mostrado en la Figura 12.




Figura 11. Perfil de impedancia para entrenamiento




Figura 12. Perfil de admitancia para entrenamiento

En el perfil de impedancia total se observan algunas discontinuidades en la gráfica, las cuales se deben a que cuando ninguna carga está encendida la

impedancia tiene un valor de infinito. Este fenómeno no se observa en la admitancia, la cual es cero para estos mismos casos.

Para definir los vectores de entrenamiento de la red de identificación de eventos, se desarrolló un algoritmo que evalúa toda la curva de potencia total e identifica los momentos en los cuales el delta de potencia supera el umbral de 19 W previamente establecido. De acuerdo a esto, se encontraron 780 posibles eventos.

Siguiendo la estructura establecida para esta red, los vectores de entrada tienen la forma que se muestra en la Tabla 3, donde cada columna corresponde a un vector de entrada. A los valores de salida de esta red se les aplica la función signo, de tal forma que los valores negativos tomen el valor de -1 (no ocurre evento) y los positivos el valor de 1 (ocurre evento).

Tabla 3. Ejemplo de vectores de entrada para la red de identificación de eventos

Parámetro	Número de evento				
	1	2	3	4	5
P(t-1)	0	0,5259	0	0,2866	0,5259
P(t)	0,5271	0	0,2875	0	0

Los valores de potencia activa de la Tabla 3 se encuentran normalizados en un rango entre 0 y 1. Es deseable que estas entradas tomen valores dentro de un rango pequeño teniendo en cuenta que el incremento de pesos en una neurona es proporcional a su entrada, por lo que si se usan valores de magnitudes muy diferentes se puede afectar el aprendizaje de la red. En este caso, se aplicó una normalización lineal min/max a los datos de entrada [62], según la cual los valores originales, x_k , toman valores nuevos, x_k^* , dados por:

$$x_k^* = \left[\frac{x_k - x_1^{\min}}{x_1^{\max} - x_1^{\min}} \right] (x_2^{\max} - x_2^{\min}) + x_2^{\min} \quad (12)$$

Donde x_1^{min} y x_1^{max} son los valores mínimos y máximos del conjunto de datos de entrada, respectivamente, mientras x_2^{min} y x_2^{max} corresponden a estos valores después de la transformación. Esto quiere decir que x_2^{min} y x_2^{max} representan los límites del nuevo rango deseado para los datos. Una de las principales ventaja de este método es que se mantienen las relaciones que existen entre los patrones de entrenamiento originales [62].

Dado que el rango de los datos de entrada normalizados es de 0 a 1, la expresión para la normalización se reduce a:

$$x_k^* = \left[\frac{x_k - x_1^{min}}{x_1^{max} - x_1^{min}} \right] \quad (13)$$

La anterior expresión se emplea para normalizar los datos de entrada tanto de la red de identificación de eventos como de la red de identificación de estados. De la curva de entrenamiento se obtienen los valores mínimos y máximos que pueden tomar los parámetros eléctricos, los cuales se observan en la Tabla 4. De acuerdo a estos valores se realiza la normalización de los datos de entrada para las redes neuronales.

Cabe destacar que el valor máximo consignado para la impedancia es de 1054.2 ohm, el cual es el mayor valor que puede tomar este parámetro aparte de cuando tiende a infinito. Esto quiere decir que los valores de impedancia se normalizan de acuerdo a los límites hallados, excepto en los momentos en los cuales todas las cargas se encuentren apagadas y la impedancia sea infinito, casos en los cuales se asumirá un valor muy alto por encima del límite superior normalizado de 1. En este caso dicho valor será 10.

Por otro lado, la admitancia no se normaliza ya que se encontró que su rango de variabilidad es pequeño.

Tabla 4. Valores mínimos y máximos de los parámetros de entrada- Primer grupo de cargas

Parámetro	Min	Max
P	0	2329,26
I	0	25,58
Z	0,592	1054,2
Y	0	1,69

Con los 618 eventos que existen, se crean vectores de entrenamiento para la red de identificación de estados, de acuerdo a los diferentes parámetros de entrada establecidos. Cada una de las salidas de esta red es aproximada al entero más cercano, de tal forma que puedan ser asociadas a los estados de las cargas.

En la Figura 13 se observa el diagrama de flujo del proceso de identificación de cargas propuesto, de acuerdo a lo descrito. En este diagrama, el bloque $t=t+1$ representa la evaluación de la curva de consumo total en cada instante de tiempo, RNA 1 se refiere a la red de identificación de eventos y RNA 2 a la red de identificación de estados. Para esta última red, pueden seleccionarse los parámetros eléctricos de entrada de acuerdo a los casos previamente establecidos.

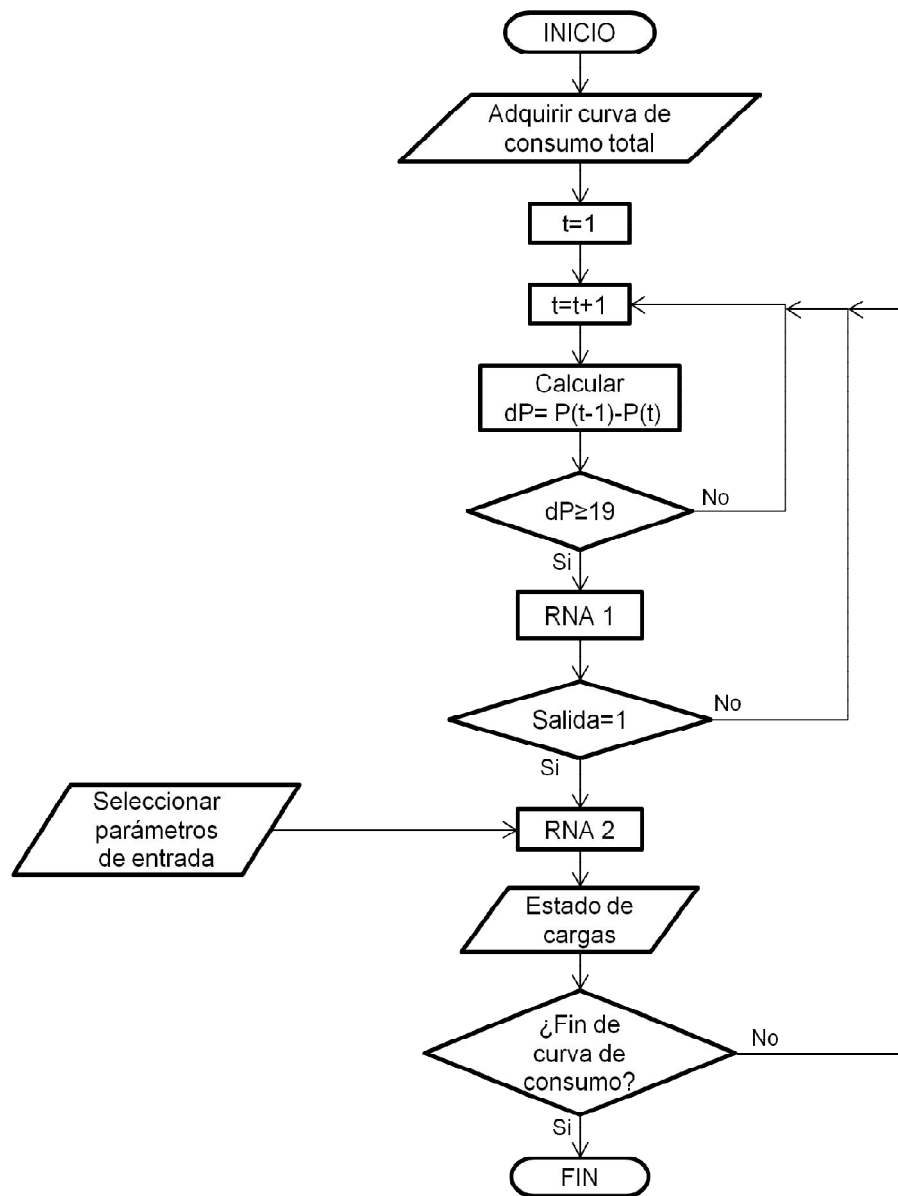


Figura 13. Diagrama de flujo del modelo propuesto

5.1.3. ENTRENAMIENTO DE LAS RNA

En el proceso de desarrollo de la red adecuada, tanto para identificación de eventos como para identificación de estados, es necesario establecer el número de neuronas adecuado que debe tener la capa oculta. Para esto, se realizaron diversos casos de entrenamiento variando el número de neuronas empleado y

registrando para cada caso el desempeño de la red. Para la red de identificación de eventos el número de neuronas ocultas se varió entre 5 y 50, mientras que para la red de identificación de estados se varió entre 10 y 90 de acuerdo a la respuesta del caso estudiado.

El entrenamiento se realiza mediante el toolbox de redes neuronales del software Matlab empleando los datos de entrenamiento previamente descritos. En cuanto a los detalles del entrenamiento se emplea el algoritmo de aprendizaje Levenberg-Marquardt, función de activación tansigmoidal en la capa oculta y función de activación lineal en la capa de salida, de acuerdo a lo recomendado para estos tipos de redes neuronales [63]. Como criterio de parada se emplearon 6 comprobaciones de validación (validation checks). Un 70% del conjunto de datos establecido fue empleado para el entrenamiento de las redes (training), un 15% para la validación (validation) y un 15% para el testeo (testing).

Para cada uno de los casos de entrenamiento, se registró el error cuadrático medio (MSE) obtenido en las fases de entrenamiento (training), validación (validation) y testeo (testing), así como también se calculó el número de eventos en los cuales la red comete errores (No. de errores) y el porcentaje de aciertos que estos representan. Los resultados para cada una de las redes son mostrados a continuación.

➤ RNA de identificación de eventos

Los resultados del entrenamiento de la red de tipo feedforward, que emplea la potencia activa como parámetro de entrada, se muestran en la Tabla 5.

Tabla 5. Entrenamiento de la red de identificación de eventos - Primer grupo de cargas

No. de Neuronas capa oculta	Tiempo de entrenamiento (mm:ss)	MSE			No. de errores	% de acierto
		TRAINING	VALIDATION	TESTING		
5	00:01	8,279E-02	4,864E-02	1,134E-01	14	98,21
10	00:01	9,093E-02	6,256E-02	7,699E-02	14	98,21
15	00:01	7,935E-02	3,559E-02	8,240E-02	11	98,59
20	00:01	7,739E-02	5,462E-02	7,338E-02	9	98,85
25	00:01	6,394E-02	9,686E-02	9,576E-02	10	98,72
30	00:01	7,437E-02	5,570E-02	5,243E-02	11	98,59
35	00:01	7,829E-02	8,030E-02	4,829E-02	10	98,72
40	00:01	7,108E-02	8,382E-02	6,627E-02	10	98,72
45	00:01	8,396E-02	8,976E-02	6,652E-02	14	98,21
50	00:01	7,010E-02	6,342E-02	5,001E-02	9	98,85

De la tabla anterior se observa que el porcentaje de acierto obtenido es alto para todos los casos de entrenamiento. Los mejores casos se presentaron con 20 y 50 neuronas en la capa oculta.

➤ RNA de identificación de estados

Para la red de identificación de estados se emplearon las arquitecturas feedforward y elman. Con cada una de estas arquitecturas se realizó la variación del número de neuronas ocultas para cada conjunto de parámetros de entrada.

Los resultados del entrenamiento de la red feedforward empleando el grupo de parámetros que incluyen la potencia activa y el grupo de parámetros de incluyen la corriente se muestran en la

Tabla 6 y la Tabla 7, respectivamente.

Tabla 6. Entrenamiento de la red feedforward de identificación de estados usando potencia activa - Primer grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (mm:ss)	MSE			No. de errores	% de acierto
			TRAINING	VALIDATION	TESTING		
P	10	00:02	9,357E-02	1,292E-01	1,055E-01	512	17,15
	20	00:07	6,540E-02	8,936E-02	6,085E-02	353	42,88
	30	00:11	3,652E-02	3,805E-02	5,901E-02	180	70,87
	40	00:15	2,196E-02	4,586E-02	2,955E-02	73	88,19
	45	00:12	1,571E-02	2,602E-02	4,585E-02	38	93,85
	50	00:08	2,804E-02	4,304E-02	4,479E-02	103	83,33
	55	00:14	2,508E-02	6,333E-02	2,955E-02	92	85,11
	60	00:04	6,845E-02	9,304E-02	9,557E-02	353	42,88
	65	00:14	2,306E-02	9,795E-02	6,434E-02	120	80,58
	70	00:10	4,600E-02	9,602E-02	1,072E-01	231	62,62
	75	00:14	2,603E-02	6,165E-02	4,693E-02	111	82,04
	80	00:15	2,791E-02	4,245E-02	3,832E-02	100	83,82
P-Z	10	00:02	9,944E-02	9,324E-02	8,769E-02	473	23,46
	20	00:09	8,849E-02	8,987E-02	7,750E-02	450	27,18
	30	00:43	3,978E-02	7,585E-02	4,229E-02	211	65,86
	40	01:00	1,601E-02	5,211E-02	1,388E-02	29	95,31
	45	00:47	2,241E-02	2,414E-02	3,862E-02	39	93,69
	50	01:04	1,826E-02	1,256E-02	3,323E-02	22	96,44
	55	01:08	1,336E-02	1,015E-02	5,528E-02	25	95,95
	60	01:16	1,461E-02	9,927E-03	4,235E-02	25	95,95
	65	01:02	1,793E-02	2,223E-02	4,608E-02	39	93,69
	70	01:58	9,942E-03	4,694E-02	2,590E-02	21	96,60
	75	01:19	1,346E-02	2,918E-02	3,642E-02	26	95,79
	80	01:23	1,873E-02	1,584E-02	3,227E-02	34	94,50
P-Y	10	00:09	9,179E-02	9,143E-02	1,288E-01	466	24,60
	20	00:04	7,287E-02	7,743E-02	7,056E-02	421	31,88
	30	00:06	6,950E-02	1,090E-01	7,869E-02	419	32,20
	40	00:14	3,241E-02	5,758E-02	3,588E-02	139	77,51
	45	00:22	2,676E-02	6,869E-02	5,679E-02	127	79,45
	50	00:09	6,945E-02	8,833E-02	6,759E-02	397	35,76
	55	00:13	6,825E-02	1,452E-01	7,520E-02	397	35,76
	60	00:14	6,351E-02	8,693E-02	1,326E-01	371	39,97
	65	00:13	6,275E-02	9,981E-02	8,056E-02	379	38,67
	70	00:30	4,280E-02	5,061E-02	2,056E-01	228	63,11
	75	00:13	7,151E-02	7,160E-02	7,580E-02	377	39,00
	80	00:13	6,841E-02	8,668E-02	8,364E-02	395	36,08

Tabla 7. Entrenamiento de la red feedforward de identificación de estados usando corriente - Primer grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (mm:ss)	MSE			No. de errores	% de acierto
			TRAINING	VALIDATION	TESTING		
I	10	00:04	9,597E-02	1,090E-01	7,976E-02	423	31,55
	20	00:02	1,036E-01	1,045E-01	1,060E-01	463	25,08
	30	00:03	9,369E-02	1,306E-01	9,513E-02	409	33,82
	40	00:13	5,017E-02	8,551E-02	8,325E-02	231	62,62
	45	00:07	5,896E-02	9,274E-02	1,137E-02	246	60,19
	50	00:08	7,026E-02	9,528E-02	2,190E-01	322	47,90
	55	00:14	8,640E-02	1,505E-01	1,241E-01	396	35,92
	60	00:06	7,303E-02	1,396E-01	9,598E-02	357	42,23
	65	00:21	4,514E-02	1,002E-01	6,992E-02	186	69,90
	70	00:10	6,407E-02	8,463E-02	9,243E-02	286	53,72
	75	00:06	7,933E-02	1,554E-01	1,534E-01	380	38,51
	80	00:12	6,287E-02	1,023E-01	9,581E-02	268	56,63
	85	00:15	5,835E-02	1,147E-01	1,866E-01	259	58,09
	90	00:11	5,931E-02	1,588E-01	1,654E-01	317	48,71
I-Z	10	00:08	9,378E-02	8,269E-02	9,861E-02	415	32,85
	20	00:07	8,954E-02	8,542E-02	1,168E-01	412	33,33
	30	00:25	6,539E-02	7,568E-02	1,085E-01	291	52,91
	40	00:48	5,687E-02	6,679E-02	9,080E-02	270	56,31
	45	01:07	5,202E-02	6,338E-02	6,314E-02	250	59,55
	50	00:34	6,383E-02	7,347E-02	9,025E-02	276	55,34
	55	00:28	8,461E-02	8,424E-02	8,545E-02	366	40,78
	60	00:38	5,805E-02	9,051E-02	1,390E-01	292	52,75
	65	00:49	5,510E-02	6,481E-02	1,058E-01	265	57,12
	70	00:54	4,680E-02	9,415E-02	6,438E-02	232	62,46
	75	00:24	7,650E-02	8,397E-02	9,764E-02	358	42,07
	80	01:07	5,722E-02	7,622E-02	6,975E-02	222	64,08
	85	01:45	4,156E-02	6,370E-02	1,067E-01	177	71,36
	90	00:59	6,142E-02	9,159E-02	1,190E-01	289	53,24
I-Y	10	00:01	1,426E-01	1,433E-01	1,372E-01	558	9,71
	20	00:05	7,864E-02	1,138E-01	9,004E-02	423	31,55
	30	00:16	6,343E-02	6,893E-02	7,804E-02	351	43,20
	40	00:11	7,602E-02	7,916E-02	1,705E-01	407	34,14
	45	00:11	7,404E-02	9,969E-02	1,984E-01	398	35,60
	50	00:15	7,717E-02	9,600E-02	1,035E-01	397	35,76
	55	00:12	6,987E-02	1,344E-01	1,086E-01	375	39,32
	60	00:37	5,625E-02	6,618E-02	1,152E-01	286	53,72
	65	00:12	7,115E-02	9,077E-02	1,343E-01	401	35,11
	70	00:18	7,888E-02	9,387E-02	9,065E-02	404	34,63
	75	00:27	5,996E-02	1,093E-01	2,490E-01	363	41,26
	80	00:24	6,231E-02	1,275E-01	4,447E-01	377	39,00
	85	00:23	6,807E-02	1,003E-01	1,570E-01	380	38,51
	90	00:47	6,007E-02	9,744E-02	2,089E-01	305	50,65

Por su parte, los resultados del entrenamiento de la red elman se encuentran consignados en la Tabla 8 y la Tabla 9.

Tabla 8. Entrenamiento de la red elman de identificación de estados usando potencia activa - Primer grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (hh:mm:ss)	No. de errores	% de acierto
P	10	00:10:17	478	22,654
	20	00:04:36	475	23,139
	30	00:20:27	122	80,259
	40	00:34:20	42	93,204
	45	00:50:25	44	92,880
	50	00:22:36	375	39,320
	55	00:27:38	397	35,761
	60	00:18:51	470	23,948
	65	00:51:15	410	33,657
P-Z	10	00:04:14	458	25,890
	20	00:08:00	329	46,764
	30	00:20:36	153	75,243
	40	00:13:37	377	38,997
	45	00:33:28	253	59,061
	50	00:25:22	380	38,511
	55	1:12:56	30	95,146
	60	1:10:04	101	83,657
	65	00:34:59	399	35,437
P-Y	10	00:03:33	476	22,977
	20	00:04:23	494	20,065
	30	00:11:22	253	59,061
	40	00:06:38	456	26,214
	45	00:29:53	288	53,398
	50	00:21:45	373	39,644
	55	00:29:34	406	34,304
	60	00:24:55	416	32,686
	65	00:40:07	408	33,981

Tabla 9. Entrenamiento de la red elman de identificación de estados usando corriente - Primer grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (hh:mm:ss)	No. de errores	% de acierto
I	10	00:06:07	437	29,288
	20	00:07:15	412	33,333
	30	00:15:27	424	31,392
	40	00:16:35	423	31,553
	45	00:35:44	226	63,430
	50	00:29:14	327	47,087
	55	00:27:21	431	30,259
	60	00:34:22	421	31,877
	65	00:55:17	397	35,761
I-Z	10	00:03:17	424	31,392
	20	00:03:00	522	15,534
	30	00:15:45	406	34,304
	40	00:12:20	396	35,922
	45	00:23:06	386	37,540
	50	00:08:56	524	15,210
	55	00:10:07	542	12,298
	60	00:17:12	536	13,269
	65	00:20:55	557	9,871
I-Y	10	00:03:52	509	17,638
	20	00:06:23	369	40,291
	30	00:14:27	364	41,100
	40	00:08:18	478	22,654
	45	00:05:10	573	7,282
	50	00:23:29	436	29,450
	55	00:26:41	395	36,084
	60	00:37:02	408	33,981
	65	00:11:16	575	6,958

Se observa que la red elman requiere de un tiempo de entrenamiento mucho mayor que la red feedforward. Debido a esto y al hecho de que con 60 y 65 neuronas no se produce un incremento significativo en el desempeño de la red elman, el número de neuronas ocultas no se incrementa más allá de 65.

Con base en los resultados consignados en las tablas anteriores, se compara gráficamente el porcentaje de acierto obtenido para cada conjunto de parámetros empleando las redes feedforward y elman, lo cual se observa desde la Figura 14 hasta la Figura 19.




Figura 14. Porcentaje de acierto redes feedforward y elman con parámetro P - Primer grupo de cargas




Figura 15. Porcentaje de acierto redes feedforward y elman con parámetros P-Z - Primer grupo de cargas




Figura 16. Porcentaje de acierto redes feedforward y elman con parámetros P-Y - Primer grupo de cargas




Figura 17. Porcentaje de acierto redes feedforward y elman con parámetro I - Primer grupo de cargas




Figura 18. Porcentaje de acierto redes feedforward y elman con parámetros I-Z - Primer grupo de cargas




Figura 19. Porcentaje de acierto redes feedforward y elman con parámetros I-Y - Primer grupo de cargas

De las figuras anteriores, se observa que en la mayoría de los casos la red feedforward arroja un porcentaje de acierto mayor que la red elman. Comparando para cada conjunto de parámetros de entrada se obtienen los resultados mostrados en la Tabla 10, donde se indica para cuantos casos de neuronas

ocultas fue mejor cada red. De igual forma, el mayor porcentaje de acierto para cada conjunto de parámetros de entrada fue obtenido con la red feedforward.

Tabla 10. Mejor porcentaje de acierto red feedforward vs red elman - Primer grupo de cargas

Parámetros de entrada	No. De casos con mejor % de acierto	
	Feedforward	Elman
P	6	3
P-Z	6	3
P-Y	7	2
I	7	2
I-Z	9	0
I-Y	7	2

Una vez se ha identificado que la red feedforward presenta un mejor desempeño que la red elman para la identificación de los estados de las cargas, se procede a evaluar los resultados obtenidos con cada conjunto de parámetros de entrada.

Así, en la Figura 20 se observa que el porcentaje de aciertos obtenido empleando la potencia activa como parámetro de entrada es significativamente más alto que el obtenido cuando se emplea la corriente en la mayoría de los casos.




Figura 20. Porcentaje de acierto red feedforward parámetros P e I - Primer grupo de cargas

En la Figura 21 se muestra el porcentaje de acierto obtenido para los conjuntos de parámetros de entrada que emplean potencia activa. En esta figura puede apreciarse que los mejores resultados se obtienen cuando la potencia se usa en conjunto con la impedancia (P-Z), caso para el cual a partir de 40 neuronas en la capa oculta se observa un desempeño alto y estable. Por el contrario, cuando se emplea la potencia activa y la admitancia (P-Y) el porcentaje de acierto resulta ser bajo para la mayoría de los casos.

Un resultado similar al anterior se obtiene para los conjuntos de parámetros de entrada que emplean corriente, cuyas gráficas se muestran en la Figura 22. En este caso, los mejores porcentajes de acierto se obtienen para los parámetros de entrada de corriente e impedancia, seguidos por el parámetro de solo corriente, y por último se encuentran los parámetros de corriente y admitancia. Los conjuntos de parámetros de entrada que emplean la corriente presentaron una menor estabilidad en el desempeño para los diferentes casos de neuronas ocultas.




Figura 21. Porcentaje de acierto red feedforward parámetros P, P-Z y P-Y - Primer grupo de cargas




Figura 22. Porcentaje de acierto red feedforward parámetros I, I-Z e I-Y - Primer grupo de cargas

5.2. SEGUNDO GRUPO DE CARGAS

5.2.1. ANÁLISIS DE LAS CARGAS

La base de datos AMPds contiene mediciones de los 19 circuitos individuales que se muestran en la Tabla 11. Cada circuito se encuentra identificado con una etiqueta (ID) asociada a las cargas que contiene, expresadas en inglés.

Tabla 11. Circuitos de la base de datos AMPds

ID	Carga
B1E	Habitación norte
B2E	Habitación sur
BME	Tomacorrientes y luces del sótano
CDE	Secadora de ropa
CWE	Lavadora de ropa
DNE	Tomacorrientes del comedor
DWE	Lavavajillas
EBE	Banca electrónica
EQE	Seguridad/Red
FGE	Refrigerador
FRE	HVAC/Horno
GRE	Garaje
HPE	Bomba de calor

HTE	Unidad de agua caliente instantánea
OFE	Oficina
OUE	Tomacorriente exterior
TVE	Televisor/PVR/Amplificación
UTE	Tomacorriente del cuarto de servicio
WOE	Horno de pared

De la anterior tabla puede observarse que algunos circuitos están conformados por una sola carga específica y otros están conformados por varias cargas. Ante esto, interesa seleccionar 2 circuitos de cada tipo para aplicar al modelo de monitoreo no intrusivo. Para establecer estos circuitos, se determina cuales de ellos son más influyentes en el consumo de energía eléctrica del hogar, lo cual puede determinarse mediante un análisis de correlación entre la potencia consumida por cada circuito y la potencia total medida de la instalación. Los resultados de dicho análisis, para tres meses de medidas, se muestran en la Tabla 12.

Tabla 12. Coeficiente de correlación entre el consumo de los circuitos y la potencia total de la instalación

Tipo de circuito	Nombre del circuito	Coeficiente de correlación
Varias cargas	B1E	0,068
	B2E	0,175
	BME	0,274
	DNE	0,102
	EQE	0,003
	GRE	0,022
	OFE	0,131
	OUE	0,014
	TVE	0,204
	UTE	-0,014
Una carga	CDE	0,641
	CWE	0,077
	DWE	0,179
	FGE	0,087
	FRE	0,257
	HPE	0,582
	HTE	0,088
	WOE	0,172

De la tabla anterior puede observarse que las cargas individuales que más influyen en el consumo total son la secadora de ropa (CDE) y la bomba de calor (HPE). A pesar de esto, el circuito CDE no se selecciona debido a que al realizar un análisis de sus medidas registradas se encontró que cuando la potencia activa y reactiva son ambas cero, la potencia aparente tiene un valor alto inconsistente. Por esto, se analizan los circuitos FRE y DWE los cuales están constituidos por las cargas individuales más influyentes en el consumo total, después de la bomba y la secadora de ropa. Al analizar el circuito FRE se encontró que este es de consumo de potencia permanente, es decir que solo se observa un estado de operación, por lo cual se decide emplear el circuito DWE para apreciar mejor la aplicación del modelo de monitoreo no intrusivo en la identificación de los estados de las cargas. Por lo tanto, las cargas individuales seleccionadas son la bomba de calor (HPE) y el lavavajillas (DWE).

En cuanto a los circuitos conformados por diferentes cargas, se seleccionan los que tienen mayor coeficiente de correlación con la potencia total, es decir, los circuitos BME y TVE.

Para estas cargas se cuenta con medidas de varios parámetros eléctricos durante un período de un año, pero no se cuenta con la información del estado en que se encuentran las cargas en cada momento de la medición. Por lo tanto, para cada uno de los 4 circuitos seleccionados (HPE, DWE, TVE y BME), es necesario realizar un análisis del comportamiento del consumo de energía para establecer sus características principales y sus estados de operación. Los resultados de este análisis para cada circuito se muestran a continuación:

- HPE (BOMBA DE CALOR)

El circuito HPE está conformado por una sola carga, la cual es una bomba de calor. Esta carga es de estados finitos, como puede apreciarse en su perfil de consumo de potencia activa mostrado en la Figura 23.




Figura 23. Perfil de consumo de potencia de la carga HPE

Inspeccionando el perfil de potencia de esta carga, se observa que posee dos estados apreciables: un estado de consumo bajo y un estado de consumo alto. Es posible definir dichos estados estableciendo límites de potencia para cada uno de ellos, tal como se muestra en la Tabla 13.

Tabla 13. Estados de operación de HPE

Estado	Potencia [W]	
	Desde	Hasta
1	0	50
2	51	en adelante

Durante un período de tres meses se analizó la curva de potencia activa de la carga, asignando a cada medida registrada los estados previamente establecidos y calculando el valor del delta de potencia para cada evento de cambio de estado. Se encontró que el delta mínimo de potencia para cambio de estado en esta carga es de 52 W.

- BME (Tomacorrientes y luces del sótano)

El circuito BME está conformado por tomacorrientes y luces del sótano del hogar, por lo cual es un circuito que contiene varias cargas. Su perfil de potencia activa, mostrado en la Figura 24, indica que este circuito puede ser dividido en tres niveles de consumo de potencia (bajo, medio y alto).




Figura 24. Perfil de consumo de potencia de la carga BME

De acuerdo a los niveles de consumo de potencia activa observados, se definen tres estados de operación de la forma que se indica en la Tabla 14. Cabe resaltar que los estados de operación para esta carga son rotulados a partir del número 3, ya que los estados 1 y 2 fueron previamente asociados a la carga HPE.

Tabla 14. Estados de operación de BME

Estado	Potencia [W]	
	Desde	Hasta
3	0	45
4	46	150
5	151	en adelante

Mediante el cálculo del delta de potencia cuando ocurre un cambio de estado, durante un período de 3 meses, se encontró que el delta mínimo para esta carga es de 21 W.

- TVE (Televisor/PVR/Amplificación)

El circuito TVE está conformado por varias cargas de entretenimiento como lo son un televisor, un PVR (personal video recorder) y su amplificación asociada.




Figura 25. Perfil de consumo de potencia de la carga TVE

En el perfil de consumo de potencia activa de este circuito, mostrado en la Figura 25, se observa que este posee un estado de consumo bajo aproximadamente constante, y un estado de consumo alto que presenta bastante variabilidad. Por lo tanto, este circuito se modelará como una carga de dos estados, definidos como se muestra en la Tabla 15.

Tabla 15. Estados de operación de TVE

Estado	Potencia [W]	
	Desde	Hasta
6	0	66
7	67	en adelante

Bajo estas consideraciones, se encontró que el delta mínimo de potencia durante cambios de estado tiene un valor de 24 W.

- DWE (Lavavajillas)

El circuito DWE es un circuito dedicado para el lavavajillas del hogar. Su perfil de consumo de potencia activa se muestra en la Figura 26. De dicho perfil se observa que esta carga presenta períodos prolongados en los cuales se encuentra apagada, y consume una potencia muy baja o nula. Cuando la carga es encendida su consumo varía entre dos estados, de los cuales se observa que uno de ellos consume una potencia significativamente mayor con respecto al otro.




Figura 26. Perfil de consumo de potencia de la carga DWE

Analizando los tres estados de operación identificados en el perfil de consumo de potencia activa, se establecen los límites para cada uno de ellos de la forma que se muestra en la Tabla 16.

Tabla 16. Estados de operación de DWE

Estado	Potencia [w]	
	Desde	Hasta
8	0	30
9	31	190
10	191	en adelante

El análisis de los cambios de estado de operación en la curva de potencia arrojó que para la carga DWE el delta mínimo de cambio de estado es de 55 W.

De acuerdo a las características mostradas para cada carga, se observa que cuando ocurren cambios de estado el mínimo delta de potencia se da para la carga BME, con un valor de 21 W. Considerando un margen de error de 10%, se establece el delta mínimo de potencia para cambio de estado en 19 W.

5.2.2. DATOS DE ENTRENAMIENTO DE LAS RNA

Para el segundo grupo de cargas, el entrenamiento de las redes neuronales artificiales se realiza tomando un tiempo significativo del año de medidas con que se cuenta. De esta forma, se establece un tiempo de 3 meses, durante el cual se tiene información suficiente del comportamiento de las cargas y sus cambios de estado de operación. Debido a que la carga DWE presenta una menor frecuencia de uso que las demás, a las medidas registradas en la base de datos durante el período de 3 meses considerado se les introdujo la repetición de siete períodos durante los cuales la carga está encendida. Esto con el fin de que aumentará el número de eventos para esta carga y se obtuviera un mejor conjunto de entrenamiento.

Las curvas de entrenamiento de potencia activa y corriente total están conformadas por la suma de los respectivos parámetros eléctricos de cada una de las cuatro cargas consideradas. Estos perfiles se muestran en la Figura 27 y en la Figura 28.




Figura 27. Perfil de potencia para entrenamiento




Figura 28. Perfil de corriente para entrenamiento

De la Figura 27 y la Figura 28 se observa que los perfiles de potencia activa y de corriente presentan un comportamiento similar, siendo la principal diferencia el rango en el cual varía cada uno de ellos.

Por otro lado, los perfiles de impedancia y admitancia son obtenidos aplicando las relaciones previamente descritas en la ecuación (11). Las gráficas correspondientes a estos perfiles se muestran en la Figura 29 y en la Figura 30.

Del perfil de impedancia para el entrenamiento se observa que este no presenta discontinuidades. Esto sucede debido a que algunas de las cargas consideradas siempre están consumiendo algún nivel de potencia, por lo cual la potencia total nunca es cero y la impedancia no llega a ser infinita.




Figura 29. Perfil de impedancia para entrenamiento




Figura 30. Perfil de admitancia para entrenamiento

Al evaluar la curva de potencia total con el delta mínimo identificado (19 W), se encontró que existen 10520 posibles eventos, de los cuales 2641 corresponden a

eventos reales. Por lo tanto, se tienen 10520 vectores de entrenamiento para la red de identificación de eventos y 2641 para la red de identificación de estados.

Los vectores de entrenamiento de las redes neuronales poseen la misma estructura previamente descrita para el primer grupo de cargas y sus parámetros están igualmente normalizados mediante la normalización lineal min/max. Esta última es aplicada empleando los valores mínimos y máximos de los parámetros eléctricos, mostrados en la Tabla 17. Nuevamente se observa que la admitancia presenta una baja variabilidad, por lo tanto a este parámetro no se le aplica la normalización.

Tabla 17. Valores mínimos y máximos de los parámetros de entrada- Segundo grupo de cargas

Parámetro	Min	Max
P	37	3346
I	0,6	29
Z	4	208
Y	0,0048	0,25

El diagrama de flujo para el segundo grupo de cargas es igual al previamente mostrado en la Figura 13.

5.2.3. ENTRENAMIENTO DE LAS RNA

Las características de las redes neuronales artificiales y el procedimiento seguido para su entrenamiento son análogos a lo descrito previamente para el primer grupo de cargas en la sección 5.1.3. A continuación se muestran los resultados del entrenamiento para cada una de las redes.

➤ RNA de identificación de eventos

La variación del número de neuronas en la capa oculta para la red feedforward de identificación de eventos arroja los resultados de desempeño mostrados en la Tabla 18.

Tabla 18. Entrenamiento de la red de identificación de eventos - Segundo grupo de cargas

No. de Neuronas	Tiempo de entrenamiento (MM:SS)	MSE			No. de errores	% de acierto
		TRAINING	VALIDATION	TESTING		
5	00:02	1,436E-01	1,741E-01	1,655E-01	426	95,95
10	00:03	1,470E-01	1,555E-01	1,336E-01	422	95,99
15	00:04	1,421E-01	1,572E-01	1,455E-01	389	96,30
20	00:11	1,261E-01	1,194E-01	1,352E-01	426	95,95
25	00:30	9,631E-02	1,017E-01	1,108E-01	241	97,71
30	00:16	1,096E-01	1,213E-01	1,014E-01	328	96,88
35	00:59	9,668E-02	1,179E-01	1,217E-01	271	97,42
40	01:42	8,513E-02	9,244E-02	1,513E-01	222	97,89
45	00:40	8,733E-02	9,931E-02	1,102E-01	252	97,60
50	01:02	9,045E-02	1,059E-01	1,088E-01	236	97,76

Los resultados de la tabla anterior muestran que la red tiene un alto porcentaje de acierto en todo el rango de número de neuronas empleado. El menor número de errores se comete cuando se tienen 40 neuronas en la capa oculta.

➤ RNA de identificación de estados

La red feedforward de identificación de estados fue entrenada variando el número de neuronas ocultas en un rango entre 10 y 80. Los resultados de MSE, número de eventos en los que comete errores y porcentaje de acierto son mostrados en la Tabla 19 y la Tabla 20, de acuerdo a los diferentes parámetros de entrada empleados.

Tabla 19. Entrenamiento de la red feedforward de identificación de estados usando potencia activa - Segundo grupo de cargas

Parámetros	No. de neuronas	Tiempo de entrenamiento (mm:ss)	MSE			No. de errores	% de acierto
			TRAINING	VALIDATION	TESTING		
P	10	00:11	7,209E-02	7,173E-02	7,211E-02	899	65,96
	20	00:19	3,662E-02	5,953E-02	5,488E-02	473	82,09
	30	00:14	4,793E-02	6,212E-02	5,063E-02	642	75,69
	40	00:19	3,642E-02	4,111E-02	5,739E-02	491	81,41
	45	00:33	2,410E-02	3,756E-02	6,321E-02	329	87,54
	50	00:34	3,402E-02	6,535E-02	5,988E-02	408	84,55
	55	00:34	2,834E-02	4,666E-02	5,897E-02	307	88,38
	60	00:31	2,573E-02	5,758E-02	2,998E-02	305	88,45
	65	00:56	2,289E-02	2,496E-02	4,941E-02	276	89,55
	70	01:16	2,125E-02	3,245E-02	5,849E-02	270	89,78
	75	00:32	2,785E-02	4,320E-02	9,440E-02	385	85,42
	80	00:54	2,773E-02	5,151E-02	6,351E-02	321	87,85
P-Z	10	00:13	5,284E-02	6,016E-02	5,862E-02	639	75,80
	20	01:26	3,027E-02	3,196E-02	2,659E-02	396	85,01
	30	00:14	4,389E-02	5,562E-02	5,062E-02	569	78,46
	40	01:15	1,884E-02	3,032E-02	4,377E-02	273	89,66
	45	01:35	2,003E-02	2,800E-02	3,331E-02	275	89,59
	50	01:29	1,968E-02	2,551E-02	3,276E-02	265	89,97
	55	01:08	2,281E-02	3,098E-02	3,057E-02	313	88,15
	60	01:22	1,876E-02	2,857E-02	3,332E-02	280	89,40
	65	02:12	1,635E-02	2,344E-02	4,116E-02	226	91,44
	70	01:47	1,906E-02	5,497E-02	4,023E-02	278	89,47
	75	01:19	2,154E-02	3,621E-02	4,061E-02	312	88,19
	80	01:24	2,032E-02	3,112E-02	4,252E-02	296	88,79
P-Y	10	00:11	6,643E-02	7,162E-02	7,431E-02	866	67,21
	20	00:25	4,527E-02	6,553E-02	4,777E-02	613	76,79
	30	01:02	2,336E-02	2,835E-02	5,545E-02	329	87,54
	40	00:33	3,347E-02	3,690E-02	3,855E-02	426	83,87
	45	00:52	2,387E-02	4,206E-02	3,148E-02	345	86,94
	50	00:42	2,567E-02	3,100E-02	4,581E-02	328	87,58
	55	01:03	2,236E-02	2,969E-02	3,395E-02	299	88,68
	60	01:24	2,024E-02	3,785E-02	3,078E-02	274	89,63
	65	01:09	3,073E-02	3,480E-02	3,786E-02	383	85,50
	70	01:23	2,191E-02	2,864E-02	3,786E-02	274	89,63
	75	01:40	2,599E-02	4,575E-02	5,593E-02	346	86,90
	80	00:53	3,405E-02	5,370E-02	4,414E-02	459	82,62

Tabla 20. Entrenamiento de la red feedforward de identificación de estados usando corriente - Segundo grupo de cargas

Parámetros	No. de neuronas	Tiempo de entrenamiento (mm:ss)	MSE			No. de errores	% de acierto
			TRAINING	VALIDATION	TESTING		
I	10	00:25	7,287E-02	7,821E-02	7,627E-02	933	64,67
	20	00:27	4,040E-02	4,390E-02	5,282E-02	570	78,42
	30	00:14	4,914E-02	5,874E-02	5,362E-02	730	72,36
	40	00:22	3,804E-02	5,588E-02	7,195E-02	484	81,67
	45	00:42	2,607E-02	3,062E-02	3,248E-02	303	88,53
	50	00:24	3,980E-02	6,042E-02	4,858E-02	535	79,74
	55	00:24	3,631E-02	4,472E-02	3,498E-02	419	84,13
	60	00:21	3,892E-02	5,974E-02	6,348E-02	500	81,07
	65	00:36	2,927E-02	3,534E-02	4,000E-02	329	87,54
	70	00:22	4,158E-02	4,805E-02	5,632E-02	551	79,14
	75	00:44	2,861E-02	5,724E-02	6,098E-02	379	85,65
	80	00:39	2,741E-02	3,974E-02	4,606E-02	319	87,92
I-Z	10	00:13	5,104E-02	5,471E-02	5,325E-02	737	72,09
	20	00:45	3,327E-02	3,635E-02	3,921E-02	425	83,91
	30	00:35	3,014E-02	3,238E-02	3,375E-02	391	85,20
	40	01:10	2,112E-02	2,971E-02	4,485E-02	324	87,73
	45	01:16	2,729E-02	3,229E-02	3,176E-02	354	86,60
	50	00:30	3,200E-02	3,883E-02	4,354E-02	414	84,32
	55	00:57	2,576E-02	3,536E-02	5,101E-02	354	86,60
	60	00:50	1,981E-02	2,770E-02	3,740E-02	263	90,04
	65	03:00	1,937E-02	2,732E-02	3,665E-02	270	89,78
	70	02:21	1,888E-02	3,524E-02	2,730E-02	264	90,00
	75	01:55	2,014E-02	2,669E-02	3,925E-02	289	89,06
	80	01:39	2,026E-02	3,317E-02	3,014E-02	284	89,25
I-Y	10	00:48	5,660E-02	5,778E-02	6,412E-02	819	68,99
	20	00:51	3,345E-02	3,772E-02	5,195E-02	462	82,51
	30	00:25	3,814E-02	6,200E-02	5,210E-02	551	79,14
	40	00:40	3,347E-02	4,862E-02	6,815E-02	428	83,79
	45	02:11	2,098E-02	3,096E-02	4,004E-02	286	89,17
	50	01:01	2,649E-02	3,955E-02	3,532E-02	363	86,26
	55	03:11	1,812E-02	2,519E-02	3,366E-02	229	91,33
	60	01:32	2,644E-02	4,135E-02	4,389E-02	353	86,63
	65	01:15	2,207E-02	4,232E-02	3,199E-02	299	88,68
	70	00:59	2,432E-02	5,108E-02	2,899E-02	328	87,58
	75	01:29	2,763E-02	4,053E-02	4,738E-02	363	86,26
	80	03:13	1,878E-02	3,220E-02	5,774E-02	276	89,55

Por su parte, la Tabla 21 y la Tabla 22 contienen el número de eventos erróneamente clasificados y el porcentaje de acierto que alcanza cada caso de entrenamiento de la red elman.

Tabla 21. Entrenamiento de la red elman de identificación de estados usando potencia activa - Segundo grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (hh:mm:ss)	No. de errores	% de acierto
P	10	00:14:46	860	67,437
	20	01:07:42	443	83,226
	30	04:06:29	302	88,565
	40	02:31:57	316	88,035
	45	03:38:18	437	83,453
P-Z	10	00:13:05	669	74,669
	20	00:50:54	400	84,854
	30	01:28:13	302	88,565
	40	00:49:48	419	84,135
	45	06:02:35	275	89,587
P-Y	10	00:09:16	906	65,695
	20	00:44:20	452	82,885
	30	00:53:46	465	82,393
	40	02:32:45	325	87,694
	45	12:00:42	358	86,445

Tabla 22. Entrenamiento de la red elman de identificación de estados usando corriente - Segundo grupo de cargas

Parámetros de entrada	No. de neuronas capa oculta	Tiempo de entrenamiento (hh:mm:ss)	No. de errores	% de acierto
I	10	00:13:25	801	69,671
	20	00:57:26	480	81,825
	30	00:30:40	790	70,087
	40	01:09:12	569	78,455
	45	08:32:32	598	77,357
I-Z	10	00:13:10	735	72,170
	20	00:47:13	431	83,680
	30	00:41:22	411	84,438
	40	03:05:29	277	89,512
	45	05:15:06	375	85,801
I-Y	10	00:09:06	808	69,406
	20	00:17:38	817	69,065
	30	00:49:33	439	83,378
	40	01:00:37	447	83,075
	45	14:56:33	296	88,792

Del proceso de entrenamiento de la red elman se evidencia que cada caso requiere un tiempo de entrenamiento mucho mayor en comparación con la red feedforward. Para la mayoría de los conjuntos de parámetros de entrada, cuando se tienen 45 neuronas en la capa oculta de la red elman se necesita un tiempo de entrenamiento considerablemente mayor que para el resto de casos con un número de neuronas menor. Al intentar incrementar el número de neuronas por encima de 45 se encontró que el esfuerzo computacional requerido era demasiado alto, ante lo cual varios computadores en los cuales se intentó realizar el entrenamiento quedaron con memoria insuficiente. Debido a esto, para la red elman solo se entrenó hasta 45 neuronas en la capa oculta.

Los resultados gráficos del desempeño de los dos tipos de redes bajo los diferentes parámetros de entrada se muestran desde la Figura 31 hasta la Figura 36.




Figura 31. Porcentaje de acierto redes feedforward y elman con parámetro P - Segundo grupo de cargas




Figura 32. Porcentaje de acierto redes feedforward y elman con parámetros P-Z - Segundo grupo de cargas




Figura 33. Porcentaje de acierto redes feedforward y elman con parámetros P-Y - Segundo grupo de cargas




Figura 34. Porcentaje de acierto redes feedforward y elman con parámetro I - Segundo grupo de cargas




Figura 35. Porcentaje de acierto redes feedforward y elman con parámetros I-Z - Segundo grupo de cargas




Figura 36. Porcentaje de acierto redes feedforward y elman con parámetros I-Y - Segundo grupo de cargas

Analizando en las figuras anteriores el comportamiento del desempeño de la red feedforward y el de la red elman, se observa que para muchos casos el porcentaje de acierto es cercano en ambas redes. Comparando cada uno de los casos desde 10 hasta 45 neuronas ocultas, se obtienen los resultados consignados en la Tabla

23, donde se muestra en cuantas ocasiones cada red arrojó mayores aciertos con respecto a la otra.

Tabla 23. Mejor porcentaje de acierto red feedforward vs red elman - Segundo grupo de cargas

Parámetros de entrada	No. De casos mejor	
	Feedforward	Elman
P	1	4
P-Z	3	1
P-Y	3	2
I	3	2
I-Z	3	2
I-Y	3	2

De la Tabla 23, es evidente que para la mayoría de parámetros de entrada la red feedforward arroja mejores resultados que la red elman, excepto en el caso en el que la entrada es la potencia activa. Se aclara que para los parámetros P-Z se obtuvo un caso en el cual ambas redes tuvieron el mismo porcentaje de acierto.

La limitante que presenta la red elman de solo poderse entrenar hasta 45 neuronas no ocurre con la red feedforward. Para esta última, es posible realizar el entrenamiento con números altos de neuronas en un corto tiempo. Debido a esto, la red feedforward fue entrenada hasta 80 neuronas en la capa oculta. Al analizar el porcentaje de acierto obtenido en todo el rango de entrenamiento para cada tipo de red, se encuentra que la red feedforward arroja el resultado más alto en todos los seis conjuntos de parámetros de entrada implementados.

Ante lo anterior, es de interés estudiar más en detalle los resultados obtenidos con la red feedforward para cada conjunto de parámetros de entrada. En primer lugar, se analiza el comportamiento de la red para las entradas que emplean potencia activa y para las que emplean corriente. Así, en la Figura 37 puede observarse el comportamiento de las redes que emplean solo potencia activa y solo corriente como parámetros de entrada. En esta figura se puede apreciar que la tendencia

del porcentaje de acierto es parecida para ambos parámetros, pero la red que emplea potencia activa genera mejores resultados la mayor parte de los casos y tiene más estabilidad para un número de neuronas alto.




Figura 37. Porcentaje de acierto red feedforward parámetros P e I - Segundo grupo de cargas

En la Figura 38 se aprecia la misma comparación anterior pero para los parámetros de entrada P-Z e I-Z. En este caso, el conjunto de entrada que emplea potencia activa domina para varios puntos de las gráficas. Cuando el número de neuronas ocultas es alto, los dos conjuntos de parámetros producen resultados estables muy cercanos entre sí.




Figura 38. Porcentaje de acierto red feedforward parámetros P-Z e I-Z - Segundo grupo de cargas

Por último, la comparación de los parámetros P-Y e I-Y se observa en la Figura 39. En esta se aprecia que en algunos casos domina la entrada que incluye potencia y en algunos casos domina la que incluye corriente, sin embargo no se observa claramente una dominancia total de ninguna de las dos.




Figura 39. Porcentaje de acierto red feedforward parámetros P-Y e I-Y - Segundo grupo de cargas

Por otra parte, es de interés analizar la incidencia de la impedancia y de la admitancia en el desempeño de la red. Para esto, en la Figura 40 se puede observar el porcentaje de acierto obtenido en el entrenamiento de las redes con entradas P, P-Z y P-Y, mientras en la Figura 41 se observa lo mismo para las entradas I, I-Z e I-Y. En la primera de estas figuras se aprecia que en la mayoría de los casos el mejor porcentaje de acierto se obtiene con la red P-Z. En cuanto a los parámetros P y P-Y, el segundo de estos presenta un desempeño ligeramente mejor con respecto al primero.




Figura 40. Porcentaje de acierto red feedforward parámetros P, P-Z y P-Y - Segundo grupo de cargas

Por su parte, la Figura 41 evidencia que una vez más el conjunto de entrada que emplea impedancia, en este caso I-Z, presenta el mayor número de mejor porcentaje de acierto para el rango de neuronas ocultas entrenado. El conjunto de entrada I-Y resulta ser mejor que el I-Z en unos cuantos casos y mejor que el conjunto que solo emplea la corriente en todos los casos.




Figura 41. Porcentaje de acierto red feedforward parámetros I, I-Z e I-Y - Segundo grupo de cargas

CAPÍTULO 6

ANÁLISIS DE LOS RESULTADOS EXPERIMENTALES

Este capítulo presenta los resultados y análisis de los resultados de las pruebas realizadas sobre el modelo propuesto para los dos grupos de cargas estudiados. Esto con el fin de demostrar la funcionalidad y factibilidad del modelo de monitoreo no intrusivo presentado en los capítulos anteriores para la identificación de cargas en instalaciones residenciales.

6.1. VALIDACIÓN DEL PRIMER GRUPO DE CARGAS

6.1.1. CURVAS DE PRUEBA

Con el fin de validar la capacidad de identificación de cargas del modelo desarrollado, este es probado con un conjunto nuevo de consumos totales diferentes a los empleados durante el proceso de entrenamiento de las redes neuronales. En este caso, la curva de consumo total está conformada tanto por mediciones realizadas sobre el conjunto de las cuatro cargas como por combinaciones de mediciones sobre las cargas individuales.

El perfil de potencia activa empleado para las pruebas se muestra en la Figura 42. En este, se incluyen 119 posibles eventos de los cuales 111 corresponden a eventos reales. Estos 111 eventos se clasifican de la siguiente manera:

- 76 eventos tipo 1
- 19 eventos tipo 2
- 10 eventos tipo 3
- 6 eventos tipo 4




Figura 42. Curva de potencia total de prueba - Primer grupo de cargas

Con base en las mediciones de potencia activa, potencia reactiva y corriente realizadas, se obtienen los diversos conjuntos de parámetros de entrada que se han estudiado. Estos conjuntos de prueba son aplicados a la red neuronal de identificación de eventos y a la red neuronal de identificación de estados para evaluar sus respuestas.

6.1.2. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE EVENTOS

El conjunto de 119 posibles eventos identificados en la curva de prueba, los cuales son aquellos puntos en los cuales el delta de potencia es mayor o igual a 19 W, es ingresado a las redes neuronales entrenadas para la identificación de eventos. El porcentaje de acierto obtenido para cada caso y su comparación con el resultado previamente obtenido en el entrenamiento se muestra en la Figura 43. Se observa que el resultado arrojado por las diferentes redes ante el nuevo conjunto de datos es el mismo para todos los casos, lo cual es de esperarse debido a que los porcentajes de acierto obtenidos durante el entrenamiento se encuentran en un rango pequeño.




Figura 43. Desempeño del entrenamiento y prueba de la RNA 1 - Primer grupo de cargas

De acuerdo al entrenamiento, los dos casos con mejor porcentaje de acierto corresponden a 20 y 50 neuronas en la capa oculta. El detalle de los resultados obtenidos en la prueba de estos dos casos se encuentra en la Tabla 24.

Tabla 24. Resultados de la prueba de identificación de eventos - Primer grupo de cargas

	20 neuronas		50 neuronas	
	Entrenamiento	Prueba	Entrenamiento	Prueba
No. De posibles eventos	780	119	780	119
No. De errores	9	2	9	2
% de acierto	98,85	98,32	98,85	98,32

Se observa que para 20 y 50 neuronas se obtienen resultados iguales lo cual indica que ambas redes se desempeñan de manera similar. En este caso, se selecciona la red con el menor número de neuronas, es decir, la red con 20 neuronas en la capa oculta. Seleccionando esta red para realizar la identificación de eventos, se procede a analizar su respuesta ante la aplicación de los datos de prueba. Para ello, se obtiene la matriz de confusión mostrada en la Tabla 25, la cual indica cuantas de las salidas de la red corresponden al objetivo real que esta debía alcanzar y cuantas fueron equivocadas.

Tabla 25. Matriz de confusión red de identificación de eventos - Primer grupo de cargas

		Salida de la red	
		Evento (1)	No evento (-1)
Objetivo real	Evento (1)	110	1
	No evento (-1)	1	7

De acuerdo a la matriz de confusión obtenida, en una sola ocasión la red indica que ocurrió un evento cuando en realidad no ocurrió (falso positivo), y también en una sola ocasión indica que no ocurrió un evento cuando en realidad sí ocurrió (falso negativo).

Con los valores de falsos positivos y falsos negativos arrojados por la red, es posible calcular dos indicadores conocidos como precisión y exhaustividad, los cuales se definen de la siguiente manera [64]:

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Exhaustividad = \frac{TP}{TP + FN} \quad (15)$$

Donde: TP= verdaderos positivos; FP= falsos positivos; FN=falsos negativos. En una matriz de confusión en la que se tengan dos posibles resultados, estos valores son fácilmente identificados de acuerdo a como se indica en la Tabla 26.

De acuerdo a las expresiones mostradas en las ecuaciones 14 y 15, la precisión indica que proporción de los eventos predichos corresponden a eventos reales. Por su parte, la exhaustividad representa la relación que existe entre el número de eventos correctamente predichos y el número real de eventos, es decir, indica que proporción de los eventos reales fueron correctamente predichos. Entre más cercanos se encuentren estos valores a 1 más ideales serán los resultados arrojados por el sistema.

Tabla 26. Forma de una matriz de confusión de dos resultados

		Salida de la red	
		Evento (1)	No evento (-1)
Objetivo real	Evento (1)	TP	FN
	No evento (-1)	FP	TN

De esta forma, los valores de precisión y exhaustividad para la red de identificación de eventos son:

$$Precision = Exhaustividad = \frac{110}{110 + 1} = 0,9909 \quad (16)$$

El valor obtenido para estos indicadores es cercano a 1, lo cual implica que la red de identificación de eventos presentó un buen desempeño en la prueba aplicada.

6.1.3. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE ESTADOS

El conjunto de 111 eventos de prueba previamente descrito es aplicado a las redes neuronales tipo feedforward de identificación de estados, entrenadas bajo los diferentes parámetros de entrada considerados. La Figura 44 muestra los porcentajes de acierto obtenidos para los conjuntos de parámetros de entrada que emplean potencia activa, tanto para el entrenamiento (Ent.) como para la prueba de validación. Por su parte, la Figura 45 muestra lo mismo para los conjuntos de parámetros que emplean corriente.




Figura 44. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con P - Primer grupo de cargas

En la Figura 44 se observa que en todo el rango de número de neuronas y para todos los conjuntos de parámetros de entrada, el porcentaje de acierto obtenido en la prueba es ligeramente menor que el obtenido durante el entrenamiento y mantiene un comportamiento consistente con este último.




Figura 45. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con I - Primer grupo de cargas

Para los parámetros de entrada que incluyen corriente se observa la misma relación previamente descrita entre los resultados obtenidos en la prueba y los obtenidos en el entrenamiento. En este caso, los diferentes conjuntos de parámetros de entrada poseen un comportamiento que dificulta la clara distinción entre ellos, caso contrario a lo que ocurre con los parámetros que emplean potencia activa.

De acuerdo a los resultados obtenidos del entrenamiento y la prueba, se escoge el caso de neuronas ocultas que mejor se desempeña para cada uno de los seis conjuntos de parámetros de entrada. El porcentaje de acierto y número de errores cometidos por estas redes se muestra en la Tabla 27.

Tabla 27. Resultados de la prueba de identificación de estados - Primer grupo de cargas

Parámetros de entrada		No. de eventos	No. de errores	% de acierto
P (45 neuronas)	Entrenamiento	618	38	93,85
	Prueba	111	8	92,79
PZ (50 neuronas)	Entrenamiento	618	22	96,44
	Prueba	111	6	94,59
PY (45 neuronas)	Entrenamiento	618	127	79,45
	Prueba	111	26	76,57
I (65 neuronas)	Entrenamiento	618	186	69,9
	Prueba	111	30	72,97
IZ (85 neuronas)	Entrenamiento	618	177	71,36
	Prueba	111	38	65,77
IY (60 neuronas)	Entrenamiento	618	286	53,72
	Prueba	111	60	45,95

Los resultados obtenidos muestran que para los conjuntos de parámetros de entrada que emplean corriente, el número de neuronas ocultas para el cual se obtiene un mejor resultado es mayor que para los casos en los que se emplea potencia activa como entrada a la red. De igual forma, es claro que tanto en el entrenamiento como en la prueba los mejores porcentajes de acierto se obtuvieron para el conjunto de parámetros de entrada P-Z con 50 neuronas en la capa oculta.

Ante lo anterior, es de interés conocer más profundamente los resultados obtenidos por la red P-Z, con 50 neuronas, al aplicarle la prueba de validación. De esta manera, en la Tabla 28 se encuentra la matriz de confusión arrojada por la red para los 111 eventos de prueba. Dado que ante cada evento la red debe arrojar dos resultados para cada carga (estados antes y después del evento), se tienen en total $111 \times 2 = 222$ valores objetivo para cada carga.

Tabla 28. Matriz de confusión red de identificación de estados - Primer grupo de cargas

		Salida de la red							
		1	2	3	4	5	6	7	8
Objetivo real	1	108	0	0	0	0	0	0	0
	2	1	113	0	0	0	0	0	0
	3	0	0	119	1	0	0	0	0
	4	0	0	2	100	0	0	0	0
	5	0	0	0	0	109	1	0	0
	6	0	0	0	0	0	112	0	0
	7	0	0	0	0	0	0	113	3
	8	0	0	0	0	0	0	2	104

Como se estableció anteriormente, las salidas 1-2, 3-4, 5-6, y 7-8 corresponden a las cargas A, B, C y D, respectivamente. De la matriz de confusión puede observarse que los errores que comete la red son entre estados de una misma carga pero no se confunde una carga con otra. También se observa que la carga D (ventilador) es en la cual más errores se cometen, lo cual se aprecia mejor en la Figura 46. Las barras de esta gráfica indican el porcentaje de error cometido en la identificación de cada carga para los 111 eventos de prueba. El máximo porcentaje de error obtenido es 4,505%, lo cual indica que todas las cargas son identificadas correctamente en la gran mayoría de los casos.




Figura 46. Errores según carga de la red de identificación de estados - Primer grupo de cargas

Por otro lado, la Tabla 29 indica cuántos errores se cometen de acuerdo al tipo de evento que debía ser identificado. Se destaca que el porcentaje de error obtenido para los eventos tipo 1 y tipo 2 fue bajo, mientras que para los eventos tipo 3 y tipo 4 no se cometió ningún error.

Tabla 29. Errores según tipo de evento de la red de identificación de estados - Primer grupo de cargas

	Tipo de evento			
	Tipo 1	Tipo 2	Tipo 3	Tipo 4
No. de eventos	76	19	10	6
No. de errores	5	1	0	0
% de error	6,579	5,263	0	0

6.1.4. VALIDACIÓN DEL MODELO TOTAL

En los incisos 6.1.2 y 6.1.3 se analizó por separado el desempeño de la red de identificación de eventos y la red de identificación de estados, respectivamente, ante la aplicación del conjunto de datos de prueba. En el presente inciso se analiza el desempeño del modelo completo de monitoreo no intrusivo propuesto, cuyo diagrama de flujo fue establecido en la Figura 13. Esto implica que la entrada de la red de identificación de estados depende de la salida de la red de identificación de eventos, por lo cual se deben tener en cuenta los errores asociados a ambas redes.

Al evaluar con la red neuronal de identificación de eventos los puntos de la curva de potencia total con delta de potencia mayor o igual a 19 W, se obtiene como resultado que ocurren en total 111 eventos. De estos resultados, 110 son en efecto eventos reales y 1 es un falso positivo, lo cual quiere decir que 1 de los 111 eventos identificados no es en realidad un evento. Los resultados arrojados en la identificación de los estados fueron erróneos para el falso positivo.

Como se mencionó anteriormente, el conjunto de datos de prueba cuenta con 111 eventos. De estos eventos objetivo, 105 son correctamente clasificados por el modelo de monitoreo no intrusivo, 5 son erróneamente clasificados y 1 no es identificado como un evento (falso negativo), por lo que en total se tienen 6 errores que representan un 94,59% de acierto del modelo total. Los anteriores resultados se encuentran consignados en la Tabla 30.

Tabla 30. Resultados de la clasificación de eventos del modelo total - Primer grupo de cargas

Eventos mal clasificados	Falsos negativos	Eventos bien clasificados	Total de eventos
5	1	105	111
Total de errores= 6			

En la Figura 47 se observan los porcentajes que representan los falsos negativos, los eventos mal clasificados y los eventos bien clasificados sobre el total de 111 eventos existentes. Se destaca que el porcentaje de eventos correctamente clasificados es bastante superior a los errores cometidos por el modelo.




Figura 47. Porcentajes de clasificación de eventos en la prueba del modelo total - Primer grupo de cargas

La comparación entre las salidas del modelo total y los objetivos que este debía alcanzar pueden observarse en la matriz de confusión mostrada en la Tabla 31. Una vez más se obtiene que los errores cometidos ocurren entre estados de una misma carga.

Tabla 31. Matriz de confusión de la prueba del modelo total - Primer grupo de cargas

		Salida de la red							
		1	2	3	4	5	6	7	8
Objetivo real	1	106	0	0	0	0	0	0	0
	2	2	114	0	0	0	0	0	0
	3	0	0	120	2	0	0	0	0
	4	0	0	2	98	0	0	0	0
	5	0	0	0	0	108	2	0	0
	6	0	0	0	0	0	112	0	0
	7	0	0	0	0	0	0	115	2
	8	0	0	0	0	0	0	2	103

Los errores cometidos para cada carga se ilustran en la Figura 48, donde se aprecia que los mayores errores se cometieron en las cargas B y D. Sin embargo, el porcentaje de error obtenido para todas las cargas es bastante bajo.




Figura 48. Errores según carga en la prueba del modelo total - Primer grupo de cargas

Por último, en la Tabla 32 se encuentran consignados el número de errores cometidos de acuerdo al tipo de evento ingresado a la red de identificación de estados. Se destaca que todos los eventos tipo 3 y tipo 4 fueron correctamente clasificados.

Tabla 32. Errores según tipo de evento del modelo total - Primer grupo de cargas

	Tipo de evento			
	Tipo 1	Tipo 2	Tipo 3	Tipo 4
No. de eventos	75	19	10	6
No. de errores	4	1	0	0
% de error	5,333	5,263	0	0

6.2. VALIDACIÓN DEL SEGUNDO GRUPO DE CARGAS

6.2.1. CURVAS DE PRUEBA

Para el segundo grupo de cargas, la nueva curva de consumo total destinada para probar el modelo está conformada por una semana de mediciones diferente a las semanas que fueron empleadas para realizar el entrenamiento. El perfil de potencia activa correspondiente a este período de tiempo, mostrado en la Figura 49, está conformado por 1523 posibles eventos, de los cuales 340 corresponden a eventos reales de cambios de estado de operación de las cargas.




Figura 49. Curva de potencia total de prueba - Segundo grupo de cargas

Con base en las mediciones de potencia activa, potencia reactiva y corriente consignadas en la base de datos, se obtienen los diversos conjuntos de parámetros de entrada que se han estudiado. Estos conjuntos de prueba son aplicados a la red neuronal de identificación de eventos y a la red neuronal de identificación de estados para evaluar sus respuestas.

6.2.2. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE EVENTOS

El conjunto de 1523 posibles eventos identificados en la curva de prueba es ingresado a las redes neuronales entrenadas para la identificación de eventos. El porcentaje de acierto obtenido para cada caso y su comparación con el resultado previamente obtenido en el entrenamiento se muestra en la Figura 50. Se observa que el porcentaje de acierto de las diferentes redes ante el nuevo conjunto de datos es en muchos casos mayor que el obtenido en la fase de entrenamiento, sin embargo el comportamiento de la gráfica correspondiente a la prueba conserva la misma tendencia de la gráfica correspondiente al entrenamiento.




Figura 50. Desempeño del entrenamiento y prueba de la RNA 1 -Segundo grupo de cargas

De acuerdo al entrenamiento realizado, los dos casos con mejor porcentaje de acierto corresponden a 40 y 50 neuronas en la capa oculta. El detalle de los resultados obtenidos en la prueba de estos dos casos se encuentra en la Tabla 33.

Tabla 33. Resultados de la prueba de identificación de eventos - Segundo grupo de cargas

	40 neuronas		50 neuronas	
	Entrenamiento	Prueba	Entrenamiento	Prueba
No. De posibles eventos	10520	1523	10520	1523
No. De errores	222	30	236	36
% de acierto	97,89	98,03	97,76	97,64

La red con 40 neuronas en la capa oculta genera resultados con menores errores que la red con 50 neuronas en la capa oculta, tanto en el entrenamiento como en la prueba. Por esta razón, la red con 40 neuronas es seleccionada para realizar la identificación de eventos.

Esta red seleccionada produce la matriz de confusión mostrada en la Tabla 34 cuando se le aplican los datos de prueba.

Tabla 34. Matriz de confusión red de identificación de eventos - Segundo grupo de cargas

		Salida de la red	
		Evento (1)	No evento (-1)
Objetivo real	Evento (1)	320	20
	No evento (-1)	10	1173

De la matriz de confusión obtenida es posible inferir que la red arroja 10 falsos positivos y 20 falsos negativos. Con estos valores se calculan los indicadores de precisión y exhaustividad, como se muestra en las ecuaciones 17 y 18.

$$Precision = \frac{TP}{TP + FP} = \frac{320}{320 + 10} = 0,9697 \quad (17)$$

$$Exhaustividad = \frac{TP}{TP + FN} = \frac{320}{320 + 20} = 0,9411 \quad (18)$$

Los valores de precisión y exhaustividad obtenidos son cercanos a 1, lo cual indica un buen desempeño de la red de identificación de eventos. Se observa que la precisión obtenida por la red es ligeramente mayor que la exhaustividad.

6.2.3. VALIDACIÓN DE LA RNA DE IDENTIFICACIÓN DE ESTADOS

Los 340 eventos presentes en la curva de prueba son aplicados a las redes neuronales tipo feedforward de identificación de estados, entrenadas bajo los diferentes parámetros de entrada considerados. La Figura 51 muestra los porcentajes de acierto obtenidos para los conjuntos de parámetros de entrada que emplean potencia activa, tanto para el entrenamiento (Ent.) como para la prueba

de validación. Por su parte, la Figura 52 muestra lo mismo para los conjuntos de parámetros que emplean corriente.




Figura 51. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con P - Segundo grupo de cargas

En la Figura 51 se observa que en todo el rango de número de neuronas ocultas y para todos los conjuntos de parámetros de entrada, el porcentaje de acierto obtenido en la prueba es ligeramente menor que el obtenido durante el entrenamiento y mantiene un comportamiento consistente con este último. También se aprecia que el mejor porcentaje de acierto obtenido durante la fase de prueba se dio con la red P-Z, lo cual fue el mismo resultado que se obtuvo en la fase de entrenamiento.




Figura 52. Desempeño del entrenamiento y prueba de la RNA 2 para parámetros con I - Segundo grupo de cargas

Para los parámetros de entrada que incluyen corriente se observa la misma relación previamente descrita entre los resultados obtenidos en la prueba y los obtenidos en el entrenamiento. En este caso, los porcentajes de acierto obtenidos durante la prueba alcanzan valores menores a los obtenidos con los conjuntos de parámetros de entrada que emplean potencia activa.

De acuerdo a los resultados obtenidos en el entrenamiento y la prueba de las redes neuronales, se escoge el caso de neuronas ocultas que mejor se desempeña para cada uno de los seis conjuntos de parámetros de entrada. El porcentaje de acierto y número de errores cometidos por estas redes seleccionadas se muestra en la Tabla 35.

Tabla 35. Resultados de la prueba de identificación de estados - Segundo grupo de cargas

Parámetros de entrada		No. de eventos	No. de errores	% de acierto
P (70 neuronas)	Entrenamiento	2641	270	89,78
	Prueba	340	75	77,94
PZ (65 neuronas)	Entrenamiento	2641	226	91,44
	Prueba	340	57	83,23
PY (70 neuronas)	Entrenamiento	2641	274	89,63
	Prueba	340	72	78,82
I (80 neuronas)	Entrenamiento	2641	319	87,92
	Prueba	340	66	80,59
IZ (70 neuronas)	Entrenamiento	2641	264	90
	Prueba	340	65	80,88
IY (55 neuronas)	Entrenamiento	2641	229	91,33
	Prueba	340	65	80,88

Los resultados obtenidos para el segundo grupo de cargas muestran que las mejores redes de cada conjunto de parámetros de entrada presentan desempeños que no son tan diferentes entre sí. Sin embargo, tanto en el entrenamiento como en la prueba se obtienen una vez más los mejores porcentajes de acierto con la red P-Z, en este caso con 65 neuronas en la capa oculta.

Ante lo anterior, es de interés conocer más profundamente los resultados obtenidos por la red P-Z, con 65 neuronas, al aplicarle las entradas de la prueba de validación. De esta manera, en la Tabla 36 se encuentra la matriz de confusión arrojada por la red para los 340 eventos de prueba. Dado que ante cada evento la red debe arrojar dos resultados para cada carga (estados antes y después del evento), se tienen en total $340 \times 2 = 680$ valores objetivo para cada carga.

Tabla 36. Matriz de confusión red de identificación de estados - Segundo grupo de cargas

		Salida de la red									
		1	2	3	4	5	6	7	8	9	10
Objetivo real	1	434	1	0	0	0	0	0	0	0	0
	2	4	241	0	0	0	0	0	0	0	0
	3	0	3	446	11	4	0	1	0	0	0
	4	0	0	3	6	0	0	0	0	0	0
	5	0	1	2	11	188	4	0	0	0	0
	6	0	0	0	2	3	568	20	0	0	0
	7	0	0	0	0	1	14	72	0	0	0
	8	0	0	0	0	0	0	9	595	25	3
	9	0	0	0	0	0	0	0	6	18	0
	10	0	0	0	0	0	0	0	0	0	24

Como se estableció anteriormente, los conjuntos de salida 1-2, 3-4-5, 6-7, y 8-9-10 corresponden a las cargas HPE, BME, TVE y DWE, respectivamente. En la matriz de confusión puede observarse que los errores que comete la red para la carga HPE ocurren entre los dos estados de la misma, pero esta no se confunde con otras cargas. En las otras tres cargas si se cometen algunos errores en los cuales se confunde el estado de una determinada carga con el de otra carga diferente, sin embargo el porcentaje de estos errores es inferior al 2% de los casos totales, como se muestra en la Tabla 37.

Tabla 37. Confusiones entre cargas - Segundo grupo de cargas

Carga	No. de confusiones con otras cargas	% de confusión con otras cargas
HPE	0	0
BME	9	1,32
TVE	6	0,88
DWE	9	1,32

En la matriz de confusión también puede apreciarse que la carga BME es en la cual más errores se cometen, tal como se observa en la Figura 53. Las barras de esta gráfica indican el porcentaje de error cometido en la identificación de cada carga para los 340 eventos de prueba. La carga HPE es en la cual menos errores se cometen, dado que su comportamiento de consumo de energía puede caracterizarse en dos estados que presentan poca variabilidad. La identificación de las demás cargas arroja un porcentaje de error de aproximadamente 10%, el cual se debe principalmente a que estas cargas presentan un consumo de potencia más variable. Además, las cargas BME y TVE están conformadas por varias cargas individuales, lo cual dificulta más su identificación, y la carga DWE tiene un uso bajo en comparación con las demás cargas, razón por la cual existen menos datos de entrenamiento para ella.




Figura 53. Errores según carga de la red de identificación de estados - Segundo grupo de cargas

6.2.4. VALIDACIÓN DEL MODELO TOTAL

Es de interés analizar el desempeño del modelo total de monitoreo no intrusivo de carga desarrollado, para lo cual se acoplarán las dos redes entrenadas y se les aplicará los datos de la prueba de validación.

Al evaluar con la red neuronal de identificación de eventos los puntos de la curva de potencia total con delta de potencia mayor o igual a 19 W, se obtiene como

resultado que ocurren en total 330 eventos. De estos resultados, 320 son en efecto eventos reales y 10 son falsos positivos, lo cual significa que 10 de los 330 eventos identificados no son en realidad eventos. Estos falsos positivos obtenidos fueron erróneamente clasificados por la red de identificación de estados.

Como se mencionó anteriormente, el conjunto de datos de prueba cuenta con 340 eventos. De estos eventos objetivo, 275 son correctamente clasificados por el modelo de monitoreo no intrusivo, 45 son erróneamente clasificados y 20 no son identificados como un evento (falsos negativos), por lo que en total se tienen 65 errores que representan un 80,88% de acierto del modelo total. Los anteriores resultados se encuentran consignados en la Tabla 38.

Tabla 38. Resultados de la clasificación de eventos del modelo total - Segundo grupo de cargas

Eventos mal clasificados	Falsos negativos	Eventos bien clasificados	Eventos totales
45	20	275	340
Total de errores= 65			

En la Figura 54 se observan los porcentajes que representan los falsos negativos, los eventos mal clasificados y los eventos bien clasificados sobre el total de 340 eventos existentes. Se destaca que el porcentaje de eventos correctamente clasificados es superior a los errores cometidos por el modelo.




Figura 54. Porcentajes de clasificación de eventos con el modelo total - Segundo grupo de cargas

La comparación entre las salidas del modelo total y los objetivos que este debía alcanzar pueden observarse en la matriz de confusión mostrada en la Tabla 39. Una vez más se observa que para la carga HPE los errores de identificación ocurren entre estados de la misma carga, mientras para las demás cargas sí se confunde el estado de una determinada carga con el de otra carga diferente.

Tabla 39. Matriz de confusión del modelo total - Segundo grupo de cargas

		Salida de la red									
		1	2	3	4	5	6	7	8	9	10
Objetivo real	1	422	1	0	0	0	0	0	0	0	0
	2	2	235	0	0	0	0	0	0	0	0
	3	0	0	447	12	3	0	0	0	0	0
	4	0	0	2	6	0	0	0	0	0	0
	5	0	1	6	12	167	4	0	0	0	0
	6	0	0	0	0	2	554	19	0	0	0
	7	0	0	0	0	1	19	65	0	0	0
	8	0	0	0	0	0	0	6	585	17	4
	9	0	0	0	0	0	0	0	6	18	0
	10	0	0	0	0	0	0	0	0	0	24

En la Tabla 40 se muestra el porcentaje de veces que cada carga es identificada con estados de una carga diferente. Se observa que dicho porcentaje es inferior al

2% y que para cada carga es casi el mismo que fue obtenido cuando se probó la red de identificación de estados individualmente (Tabla 37).

Tabla 40. Confusiones entre cargas con el modelo total - Segundo grupo de cargas

Carga	No. de confusiones con otras cargas	% de confusión con otras cargas
HPE	0	0
BME	5	1,47
TVE	3	0,88
DWE	6	1,76

El porcentaje de error cometido en la identificación de cada carga es mostrado en la Figura 55. En esta se confirma que en la carga HPE es en la cual menos errores se cometen mientras para las demás cargas el porcentaje de error es similar.




Figura 55. Errores según carga del modelo total - Segundo grupo de cargas

CAPÍTULO 7

CONCLUSIONES Y TRABAJO FUTURO

Este capítulo resume las principales conclusiones surgidas del desarrollo y resultados obtenidos del modelo propuesto. También se exponen posibles direcciones para investigaciones futuras que se desprenden del trabajo realizado en la presente tesis.

7.1. CONCLUSIONES

Los resultados obtenidos de la aplicación del modelo de monitoreo no intrusivo de cargas propuesto a los dos grupos de cargas estudiados, permiten establecer que se puede realizar satisfactoriamente la identificación de los estados de cada carga que conforman una instalación eléctrica, a partir de la medición del consumo total. El modelo identifica con un alto porcentaje de acierto la ocurrencia de eventos y el estado de operación de cada carga en el instante previo y en el estado posterior a la ocurrencia de un evento, tanto para cargas individuales como para circuitos conformados por varias cargas. Se destaca que el uso de dos redes neuronales, una para identificación de eventos y otra para identificación de estados, permite desarrollar un modelo completo de monitoreo no intrusivo.

Para el caso específico de cargas típicas de instalaciones residenciales consideradas en la presente tesis, se encontró que para ambos grupos de carga el delta mínimo de potencia para la identificación de eventos fue el mismo, lo cual

indica que alrededor de 19W se encuentra el valor ideal de este parámetro para instalaciones de tipo residencial.

Del proceso de entrenamiento de las redes neuronales para identificación de estados con alimentación hacia adelante aplicando retro propagación (feedforward backpropagation) y de las redes tipo elman, se obtuvo que el primer tipo de redes producía en la mayoría de los casos mejores porcentajes de acierto y su tiempo de entrenamiento era considerablemente menor con respecto a la segunda. Esto implica que la red sin realimentación resultó más idónea en la solución de problemas de monitoreo no intrusivo de carga que la red con realimentación.

A partir de las diferentes redes entrenadas para identificación de eventos y para identificación de estados, se observó que un número bajo de neuronas producía mayores errores, debido a que en estos casos las conexiones no resultan suficientes para solucionar el problema. Por lo tanto, fue necesario incrementar el número de neuronas en la capa oculta para encontrar el número óptimo para cada caso.

Con respecto a los diferentes conjuntos de parámetros de entrada empleados, se destaca que tanto para el grupo que emplea potencia activa (P, P-Z, P-Y) como para el grupo que emplea corriente (I, I-Z, I-Y) los mejores resultados se obtienen para el conjunto que contiene la impedancia, indicando la utilidad de este parámetro en la mejora del monitoreo no intrusivo de carga a pesar de que es poco usado en la literatura sobre el tema. Entre los conjuntos P-Z e I-Z, el primero arroja mejores porcentajes de acierto, lo que indica que la potencia activa permite una mejor identificación de estados de las cargas con el modelo propuesto. En términos generales, los parámetros de entrada que emplean potencia activa tuvieron un mejor desempeño que los parámetros de entrada que emplean corriente, siendo esta diferencia más amplia en el primer grupo de cargas. Lo anterior puede deberse principalmente a la precisión del sistema empleado para tomar las medidas que alimentan el modelo, lo cual implica que las características

del medidor empleado influyen en los resultados de identificación de cargas obtenidos.

En la identificación de estados de operación por parte del modelo, la mayoría de los errores ocurren al asignar a una determinada carga un estado incorrecto de la misma, es decir, es bajo el porcentaje con que a las cargas se les asigna estados de operación correspondientes a una carga diferente. Por otra parte, se obtuvo que aquellas cargas que tienen un consumo de potencia que varía en un rango pequeño para cada estado fueron mejor identificadas que aquellas que poseen un consumo más variable.

7.2. TRABAJO FUTURO

A partir del trabajo realizado en la presente tesis pueden desprenderse nuevos trabajos que mejoren el modelo de monitoreo no intrusivo de cargas desarrollado. A continuación se presentan algunos puntos que pueden revisarse.

- Determinar la incidencia de otros conjuntos de parámetros de entrada sobre la identificación de cargas. Por ejemplo, podrían probarse conjuntos de entrada conformados por tres parámetros eléctricos.
- Trabajar en la mejora de identificación de cargas con consumos de potencia variable.
- Mejorar la red de identificación de estados de tal forma que esta esté en la capacidad de indicar que ninguna carga cambia de estado en los casos en los cuales la red de identificación de eventos arroja falsos positivos.
- Probar el modelo desarrollado con medidas del consumo total tomadas en tiempo real. Esto implica el acople del modelo con un hardware externo.
- Aplicar el modelo de monitoreo no intrusivo desarrollado a otros tipos de instalaciones

BIBLIOGRAFÍA

- [1] C. W. Gellings, *The Smart Grid: Enabling Energy Efficiency and Demand Response*. Lilburn: The Fairmont Press Inc., 2009, p. 300.
- [2] M. Valocchi, A. Schurr, J. Juliano, and E. Nelson, "Plugging in the Consumer," *IBM Inst. Bus. Value*, 2008.
- [3] N. E. T. Laboratory, "Smart Grid Principal Characteristics: Enables Active Participation by Consumers," 2009.
- [4] T. Luo, G. Ault, and S. Galloway, "Demand side management in a highly decentralized energy future," in *UPEC*, 2010.
- [5] H. Najmeddine, K. El Khamlichi Drissi, C. Pasquier, C. Faure, K. Kerroum, A. Diop, T. Jouannet, and M. Michou, "State of art on load monitoring methods," in *2nd IEEE International Conference On Power and Energy (PECon 2008)*, 2008, pp. 1256–1258.
- [6] C. Cecati, G. Mokryani, A. Piccolo, and P. Siano, "An overview on the smart grid concept," *IECON 2010-36th*, pp. 3322–3327, 2010.
- [7] European Technology Platform, "SmartGrids - Strategic Deployment Document for Europe's Electricity Networks of the Future." p. 67, 2010.
- [8] National Energy Technology Laboratory, "The NETL Modern Grid Strategy Powering our 21st-Century Economy: Advanced Metering Infrastructure," 2008.
- [9] S. S. S. R. Depuru, L. Wang, V. Devabhaktuni, and N. Gudi, "Smart meters for power grid — Challenges, issues, advantages and status," *2011 IEEE/PES Power Syst. Conf. Expo.*, pp. 1–7, Mar. 2011.
- [10] REEP and UNIDO, "Energy efficiency technologies and benefits," *Sustainable Energy Regulation and Policymaking for Africa*. [Online]. Available: <http://africa-toolkit.reep.org/>. [Accessed: 27-Dec-2013].
- [11] World Energy Council, *Energy Efficiency Policies around the World: Review and Evaluation*. London, UK: World Energy Council, 2008, p. 116.
- [12] Charles River Associates, "Primer on Demand-Side Management," 2005.

- [13] ACES Inc and Pacific Consulting Services, "Demand-Side Management Glossary," 1992.
- [14] F. Boshell and O. P. Veloza, "Review of Developed Demand Side Management Programs Including Different Concepts and their Results," *2008 IEEE/PES Transm. Distrib. Conf. Expo. Lat. Am.*, pp. 1–7, Aug. 2008.
- [15] H. Sui, Y. Sun, and W.-J. Lee, "A demand Side Management Model Based on Advanced Metering Infrastructure," *4th Int. Conf. Electr. Util. Deregul. Restruct. Power Technol.*, pp. 1586–1589, Jul. 2011.
- [16] A. Ipakchi and F. Albuyeh, "Grid of the Future," *IEEE Power Energy Mag.*, vol. April, pp. 52–62, 2009.
- [17] EPRI, "The IntelliGrid Consortium: Leading to Drive to Transform the Power Delivery System," 2006.
- [18] Galvin Electricity Initiative, "The Essence of the Galvin Electricity Initiative." [Online]. Available: www.galvinpower.org. [Accessed: 29-Nov-2011].
- [19] National Energy Technology Laboratory, "A Vision for The Smart Grid," 2009.
- [20] Colombia Inteligente, "Marco Estratégico y Propuesta Proyecto Nacional de Redes Inteligentes en Colombia," 2011.
- [21] V. Giordano, F. Gangale, G. Fulli, M. Sánchez, A. Colta, I. Papaioannou, A. Mengolini, C. Alecu, T. Ojala, and I. Maschio, "Smart Grid projects in Europe : lessons learned and current developments," 2011.
- [22] B. Botte, V. Cannatelli, and S. Rogai, "The Telegestore Project in ENEL ' s Metering System," *18th Int. Conf. Electr. Distrib.*, vol. June 2005, pp. 6–9, 2005.
- [23] Fenercom, *Guía de Redes Inteligentes de energía y comunicación*. Madrid, 2011.
- [24] "PRIME Alliance." [Online]. Available: http://www.prime-alliance.org/?page_id=498. [Accessed: 12-Feb-2014].
- [25] Schneider Electric, "Monitoreo del uso de la energía : el poder de la información," 2011.
- [26] "Monitoreo de Energía Eléctrica," *Constructor Eléctrico*, 2013. [Online]. Available: <http://constructorelectrico.com/home/monitoreo-de-energia-electrica/>. [Accessed: 07-Jan-2014].
- [27] H. Chang, "Load Identification of Non-intrusive Load-monitoring System in Smart Home," *WSEAS Trans. Syst.*, vol. 9, no. 5, pp. 498–510, 2010.

- [28] D. Benyoucef, P. Klein, and T. Bier, "Smart Meter with Non-Intrusive Load Monitoring for Use in Smart Homes," *2010 IEEE Int. Energy Conf.*, pp. 96–101, Dec. 2010.
- [29] C. Reeg and T. Overbye, "Algorithm development for non-intrusive load monitoring for verification and diagnostics," *North Am. Power Symp.*, 2010.
- [30] M. Zeifman and K. Roth, "Nonintrusive appliance load monitoring: Review and outlook," *IEEE Trans. Consum. Electron.*, vol. 57, no. 1, pp. 76–84, 2011.
- [31] G. W. Hart, "Nonintrusive appliance load monitoring," *Proc. IEEE*, vol. 80, no. 12, pp. 1870–1891, 1992.
- [32] Y. Wong, Y. A. Sekercioglu, T. Drummond, and V. Wong, "Recent Approaches to Non-intrusive Load Monitoring Techniques in Residential Settings," *IEEE Comput. Intell. Appl. Smart Grid*, pp. 73–79, Apr. 2013.
- [33] K. Anderson, A. Ocneanu, D. Benitez, D. Carlson, A. Rowe, and M. Berges, "Blued: a fully labeled public dataset for event-based non-intrusive load monitoring research," *SustKDD Work. Data Min. Appl. Sustain.*, no. August 2012, 2012.
- [34] G. Hart, E. Kern, and F. Schweppe, "Non-intrusive appliance monitor apparatus," US4858141A1989.
- [35] H. Pihala, "Non-intrusive appliance load monitoring system based on a modern kWh-meter," Libella Painopalvelu Oy, Espoo, 1998.
- [36] H.-H. Chang, P.-C. Chien, L.-S. Lin, and N. Chen, "Feature Extraction of Non-intrusive Load-Monitoring System Using Genetic Algorithm in Smart Meters," *2011 IEEE 8th Int. Conf. E-bus. Eng.*, pp. 299–304, Oct. 2011.
- [37] T. Bier, D. O. Abdeslam, J. Merckle, and D. Benyoucef, "Smart Meter Systems Detection and Classification using Artificial Neural Networks," in *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society*, 2012, pp. 3324–3329.
- [38] A. Bijker, X. Xia, and J. Zhang, "Active Power Residential Non-intrusive Load Monitoring System," *IEEE Africon 2009*, no. September, pp. 1–6, 2009.
- [39] L. Farinaccio and R. Zmeureanu, "Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses," *Energy Build.*, vol. 30, no. 3, pp. 245–259, 1999.
- [40] Y. Nakano and H. Murata, "Non-intrusive Electric Appliances Load Monitoring System Using Harmonic Pattern Recognition-Trial Application to Commercial Building," *Int. Conf. Electr. Eng.*, 2007.

- [41] D. Srinivasan, W. S. Ng, and A. C. Liew, "Neural-Network-Based Signature Recognition for Harmonic Source Identification," *IEEE Trans. Power Deliv.*, vol. 21, no. 1, pp. 398–405, 2006.
- [42] S. R. Kamat, "Fuzzy logic based pattern recognition technique for non-intrusive load monitoring," in *TENCON 2004. 2004 IEEE Region 10 Conference*, 2004, vol. C, pp. 528 – 530 Vol. 3.
- [43] M. S. Tsai and Y. H. Lin, "Development of a Non-Intrusive Monitoring Technique for Appliance' Identification in Electricity Energy Management," *2011 Int. Conf. Adv. Power Syst. Autom. Prot.*, pp. 108–113, Oct. 2011.
- [44] O. Parson, S. Ghosh, M. Weal, and A. Rogers, "Non-intrusive load monitoring using prior models of general appliance types," in *Proceedings of the 26th AAAI Conference on Artificial Intelligence*, 2012, pp. 356–362.
- [45] Y.-C. Fan, X. Liu, W.-C. Lee, and A. L. P. Chen, "Efficient Time Series Disaggregation for Non-intrusive Appliance Load Monitoring," in *2012 9th International Conference on Ubiquitous Intelligence Computing and 9th International Conference on Autonomic Trusted Computing (UIC/ATC)*, 2012, pp. 248–255.
- [46] H.-T. Yang, H.-H. Chang, and C.-L. Lin, "Design a Neural Network for Features Selection in Non-intrusive Monitoring of Industrial Electrical Loads," in *Proceedings of the 11th International Conference on Computer Supported Cooperative Work in Design*, 2007, pp. 1022–1027.
- [47] S. Rahimi, A. D. C. Chan, and R. a. Goubran, "Nonintrusive load monitoring of electrical devices in health smart homes," *2012 IEEE Int. Instrum. Meas. Technol. Conf. Proc.*, pp. 2313–2316, May 2012.
- [48] L. Du, Y. Yang, D. He, R. G. Harley, T. G. Habetler, and B. Lu, "Support vector machine based methods for non-intrusive identification of miscellaneous electric loads," in *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society*, 2012, pp. 4866–4871.
- [49] A. R. Rababaah and E. Tebekaemi, "Electric Load Monitoring of Residential Buildings using Goodness of Fit and Multi-Layer Perceptron Neural Networks," *2012 IEEE Int. Conf. Comput. Sci. Autom. Eng.*, pp. 733–737, May 2012.
- [50] G. Ludger, *Artificial Intelligence - Structures and strategies for complex problem solving*, 5th ed. Pearson, 2009.
- [51] K. Kumar and G. S. M. Thakur, "Advanced Applications of Neural Networks and Artificial Intelligence: A Review," *Int. J. Inf. Technol. Comput. Sci.*, vol. 4, no. 6, pp. 57–68, Jun. 2012.

- [52] G. Kumar, *Artificial neural networks*. New Delhi: Indian Agricultural Research Institute, 2010.
- [53] M. Gestal, "Introducción a las Redes de Neuronas Artificiales." Departamento Tecnologías de la Información y las Comunicaciones - Universidad da Coruña, pp. 1–20, 2009.
- [54] C. Oropeza, "Modelado y Simulación de un Sistema de Detección de Intrusos Utilizando Redes Neuronales Recurrentes," Universidad de las Américas Puebla, 2007.
- [55] "Inteligencia Artificial - Redes Neuronales Artificiales de Elman." [Online]. Available: <http://prezi.com/do1ks77d5qvn/redes-neuronales-artificiales-elman/>. [Accessed: 19-Dec-2013].
- [56] J. Duan, D. Czarkowski, and Z. Zabar, "Neural network approach for estimation of load composition," *IEEE Int. Symp. Circuits Syst.*, pp. V–988–V–991, 2004.
- [57] H.-H. Chang and K.-L. Chen, "A New Measurement Method for Power Signatures of Non-intrusive Demand Monitoring and Load Identification," *2011 IEEE Ind. Appl. Soc. Annu. Meet.*, pp. 1–7, Oct. 2011.
- [58] J. Kolter and M. Johnson, "Redd: A Public Data Set for Energy Disaggregation Research," *Work. Data Min. Appl. Sustain.*, no. 1, pp. 1–6, 2011.
- [59] A. Reinhardt, P. Bauman, D. Burgstahler, M. Hollick, H. Chonov, M. Werner, and R. Steinmetz, "On the Accuracy of Appliance Identification Based on Distributed Load Metering Data," in *Proceedings of the 2nd IFIP Conference on Sustainable Internet and ICT for Sustainability*, 2012, pp. 1–9.
- [60] S. Barker, A. Mishra, D. Irwin, E. Cecchet, P. Shenoy, and J. Albrecht, "Smart *: An Open Data Set and Tools for Enabling Research in Sustainable Homes," in *SustKDD Workshop on Data Mining Applications in Sustainability*, 2012.
- [61] S. Makonin, F. Popowich, L. Bartram, B. Gill, and I. Bajic, "AMPds: A Public Dataset for Load Disaggregation and Eco-Feedback Research," no. EPEC, 2013.
- [62] A. Serrano, E. Soria, and J. Martín, "Redes Neuronales Artificiales." Valencia, 2010.
- [63] M. H. Beale, M. T. Hagan, and H. B. Demuth, *Neural Network Toolbox™ User's Guide R2013b*. 2013.
- [64] H. Kim, M. Marwah, M. F. Arlitt, G. Lyon, and J. Han, "Unsupervised Disaggregation of Low Frequency Power Measurements," in *Proceedings of the 11th SIAM International Conference on Data Mining*, 2011, pp. 747–758.